



DISSERTAÇÃO DE MESTRADO

**LINEARIZAÇÃO EXATA ADAPTATIVA
APLICADA AO CONTROLE PREDITIVO
DE PROCESSO DE NÍVEL MULTIVARIÁVEL**

Alfredo Américo de Freitas

Brasília, agosto de 2007

UNIVERSIDADE DE BRASÍLIA

FACULDADE DE TECNOLOGIA

UNIVERSIDADE DE BRASÍLIA
Faculdade de Tecnologia

DISSERTAÇÃO DE MESTRADO

**LINEARIZAÇÃO EXATA ADAPTATIVA
APLICADA AO CONTROLE PREDITIVO
DE PROCESSO DE NÍVEL MULTIVARIÁVEL**

Alfredo Américo de Freitas

*Relatório submetido ao Departamento de Engenharia
Elétrica como requisito parcial para obtenção
do grau de Mestre em Engenharia Elétrica*

Banca Examinadora

Prof. Dr. Ing Adolfo Bauchspiess, ENE/UnB _____
Orientador

Prof. PhD Luis Antonio Aguirre, MACSIN _____
UFMG
Examinador externo

Prof D.Sc. Geovany Araújo Borges, ENE/UnB _____
Examinador interno

Prof. D.Sc. João Yoshiyuki Ishihara _____
Suplente da Banca

Dedicatória

Este trabalho é dedicado a minha sobrinha Luana Freitas de Sousa e minha afilhada Luisa Freitas França

Alfredo Américo de Freitas

Agradecimentos

Agradeço a Deus por tudo de bom em toda minha vida.

Agradeço a todos os professores do departamento de engenharia elétrica da UnB, bem como a todo o corpo técnico e colegas de pós-graduação. Agradeço a todos os amigos do LAVSI e do LARA, especialmente a Gustavo Melo e Mariana Bernardes pelo sistema de nível de líquidos e outros trabalhos desenvolvidos no LAVSI, aos amigos Alexandre Martins, Bruno Vilhena e Ener Diniz Beckmann do LARA e Flavio Vidal do LCVC pelos momentos de ajuda e descontração e a todos os outros do GRAV. Agradeço também aos alunos de laboratório de controle dinâmico 2/2006.

Agradeço a todos os meus familiares, especialmente às minhas irmãs Ocirema e Nathália que me apoiaram e durante o desenvolvimento deste trabalho sempre estiveram ao meu lado. Agradeço aos meus avós e a minha mãe, pelo carinho e amor sincero. Agradeço a todos meus tios, especialmente a Maria José Barbosa e Nucilene Lima de Freitas França pela constante torcida e ajuda incondicional. Agradeço todos os meus primos e primas e demais parentes. Agradeço a Alexandra de Sousa Belchior pelo carinho e paciência.

Agradeço aos Professores Adolfo Bauchspiess e Geovany Araújo Borges pela ajuda durante a execução deste trabalho, pelo apoio no LAVSI e por acreditarem no meu trabalho.

Agradeço todos os meus amigos, especialmente a Assis Santos Silva, Daniel Veloso Aquino e Hebert Vilson França pela leal amizade.

Agradeço a todos os colegas do GRAV pelos momentos de trabalho e cooperação, especialmente a Alexandre Matrins, Bruno Vilhena e ao colega Flávio Vidal do Laboratório de Controle e Visão por Computador.

Alfredo Américo de Freitas

“Os que aprendem herdarão a terra, enquanto os que já sabem estão magnificamente equipados para viver num mundo que não existe mais.”

Eric Hoffer

LINEARIZAÇÃO EXATA ADAPTATIVA APLICADA AO CONTROLE PREDITIVO DE PROCESSO DE NÍVEL MULTIVARIÁVEL

Autor: Alfredo Américo de Freitas

Orientador: Adolfo Bauchspiess

Programa de Pós-graduação em Engenharia Elétrica

Brasília, agosto de 2007

Esta dissertação apresenta uma aplicação de técnicas de controle preditivo linear em sistemas não-lineares multivariáveis. A principal idéia é baseada na Linearização Exata Adaptativa que fornece um modelo dinâmico linear desacoplado para ser utilizado como modelo interno do controle *Model Predictive Control* (MPC).

A linearização exata do sistema não-linear fornece dois blocos básicos, um sistema linear dinâmico e uma transformação de variáveis não-linear estática. A adaptação ocorre com a inclusão de um filtro de Kalman estendido para estimação conjunta de estados e parâmetros do sistema não-linear. Tem-se assim uma abordagem denominada linearização exata adaptativa. Com o modelo linear obtido pode-se aplicar as técnicas de controle linear como Proporcional-Integral-Derivativo (PID), controle ótimo, controle preditivo e outras técnicas de sistemas lineares.

A abordagem apresentada utiliza técnicas de controle linear bastante difundidas e utilizadas no meio acadêmico aplicáveis a sistemas sistemas reais que, em última análise são não-lineares. Assim pode-se obter as vantagens do controle linear para controlar sistemas não-lineares utilizando a linearização exata adaptativa.

A aplicação da linearização exata adaptativa associada a controladores dos tipos MPC e PI é aplicado ao sistema de nível de líquidos do Laboratório de Automação, Visão e Sistemas Inteligentes (LAVSI). Assim controla-se um sistema não-linear em toda sua faixa de operação, mesmo sob variações paramétricas utilizando controladores lineares.

ADAPTIVE FEEDBACK LINEARIZATION APPLIED TO THE MODEL BASED PREDICTIVE CONTROL OF A MULTIVARIABLE LIQUID LEVEL PROCESS

Autor: Alfredo Américo de Freitas

Orientador: Adolfo Bauchspiess

Programa de Pós-graduação em Engenharia Elétrica

Brasília, agosto de 2007

This thesis presents the application of linear predictive control to multivariable nonlinear systems. The key contribution is the use of adaptive feedback linearization as internal model for the Model based Predictive Controller (MPC).

The feedback linearization of the nonlinear system supplies two blocks: a dynamic linear system and a nonlinear static variable transformation. The adaptation occurs by the use of an extended Kalman filter, estimating states and parameters of the nonlinear system. This approach produces the so called adaptive feedback linearization. Linear control techniques as PID, space state, optimal control, predictive control and other linear techniques can thus be applied employed on resulting dynamics.

The application of the adaptive feedback linearization in association with MPC and PI is applied in this thesis to the LAVSI's four tank liquid level process. Simulation results for different conditions and operating point are presented.

The presented approach is expected to be applicable to different real nonlinear systems where the sampling rate and computational effort of the feedback linearization.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	CONTEXTUALIZAÇÃO	1
1.2	DEFINIÇÃO DO PROBLEMA	2
1.3	OBJETIVOS DO PROJETO	3
1.4	APRESENTAÇÃO DO TEXTO	4
2	ESTRATÉGIAS DE CONTROLE NÃO-LINEAR	6
2.1	ESTIMAÇÃO PARA CONTROLE	6
2.2	CONTROLE PREDITIVO NÃO-LINEAR DIRETO	7
2.3	CONTROLE NÃO-LINEAR BASEADO EM MODELOS LINEARES	8
2.4	CONTROLE NÃO-LINEAR VIA SISTEMAS INTELIGENTES	12
2.5	LINEARIZAÇÃO EXATA ADAPTATIVA	12
2.6	RESUMO DO CAPÍTULO	13
2.7	CONCLUSÕES	14
3	SISTEMA DE NÍVEL DE LÍQUIDOS	15
3.1	MODELO NÃO-LINEAR	16
3.2	LIMITAÇÕES DE ATUAÇÃO E REFERÊNCIAS	19
3.3	CONCLUSÕES	20
4	ESTIMAÇÃO NÃO-LINEAR BASEADA NO FILTRO DE KALMAN	22
4.1	O FILTRO DE KALMAN - FK	23
4.1.1	ALGORITMO DO FILTRO DE KALMAN	24
4.2	O FILTRO DE KALMAN ESTENDIDO - FKE	25
4.2.1	ALGORITMO DO FILTRO DE KALMAN ESTENDIDO	26
4.2.2	APLICAÇÃO AO PROCESSO DE NÍVEL DE LÍQUIDOS	27
4.3	CONCLUSÕES	30
5	LINEARIZAÇÃO EXATA ADAPTATIVA	31
5.1	LINEARIZAÇÃO EXATA ADAPTATIVA	32
5.2	LINEARIZAÇÃO EXATA	33
5.3	LINEARIZAÇÃO EXATA DO SISTEMA DE NÍVEL DE 4ª ORDEM	35
5.4	LINEARIZAÇÃO EXATA ADAPTATIVA DO SISTEMA DE NÍVEL DE LÍQUIDOS	40
5.5	CONCLUSÕES	41

6	CONTROLE PREDITIVO BASEADO EM MODELO.....	43
6.1	CONTROLE PREDITIVO.....	44
6.1.1	O MODELO INTERNO DO CONTROLE PREDITIVO	46
6.1.2	A MINIMIZAÇÃO DA FUNÇÃO DE CUSTO	48
6.2	APLICAÇÃO DO MPC AO SISTEMA DE NÍVEL MULTIVARIÁVEL	48
6.3	CONCLUSÕES	50
7	RESULTADOS OBTIDOS.....	51
7.1	ESTIMAÇÃO DE ESTADOS E PARÂMETROS COM O FILTRO DE KALMAN ES- TENDIDO EM MALHA ABERTA	51
7.2	APLICAÇÃO DA LEA AO SISTEMA DE NÍVEL DE LÍQUIDOS	56
7.3	APLICAÇÃO DE CONTROLE PREDITIVO COM LEA AO SISTEMA DE NÍVEL DE LÍQUIDOS	60
7.3.1	CONTROLE PREDITIVO BASEADO EM MODELO COM LINEARIZAÇÃO EXATA ...	67
7.4	RESUMO	69
8	CONCLUSÕES E PESQUISA FUTURAS	70
8.1	CONCLUSÕES	70
8.2	PESQUISA FUTURAS	71
	REFERÊNCIAS BIBLIOGRÁFICAS	72

LISTA DE FIGURAS

1.1	Estrutura funcional da linearização exata adaptativa	3
2.1	Estrutura de Controlador Preditivo Não-Linear apresentado por Findeisen e Allgower [Findeisen 2002].....	8
2.2	Estrutura do Controlador de Fruzzetti	9
2.3	Sistema de dois tanques acoplados apresentado Poulsen et al.....	10
3.1	Imagem do Processo de Nível de Líquidos	16
3.2	Esquemático do Processo de Nível de Líquidos	17
5.1	Estrutura do Controle por Linearização Exata	32
5.2	Estrutura da Linearização Exata Adaptativa.....	33
5.3	Sistema linear obtido com a linearização exata do sistemas de nível de líquidos.....	36
5.4	Diagrama de Blocos Linearização Exata do Sistema de Nível de Líquidos	40
6.1	Estrutura de um controlador preditivo.....	45
6.2	Horizonte Deslizante em Controle Preditivo.....	46
6.3	Diagrama de Blocos da Linearização Exata Adaptativa com Controle Preditivo	49
7.1	Sinal dos Atuadores em Malha Aberta.....	52
7.2	Valores Estimados dos Estados em Malha Aberta	53
7.3	Resíduos de Estimação dos Estados em Malha Aberta	54
7.4	Valores Reais e Estimação de k_{12} , k_{23} e k_{34} em Malha Aberta	54
7.5	Valores Reais e Estimação de k_2 e k_4 em Malha Aberta	55
7.6	Diagrama de blocos do associação entre a LEA com o controle PI	56
7.7	Sinal dos Atuadores - LEA com controle PI.....	57
7.8	Valores estimados dos estados - LEA com controle PI.....	57
7.9	Resíduos de estimação dos estados - LEA com controle PI.....	58
7.10	Valores reais e estimados de k_{12} , k_{23} e k_{34} - LEA com controle PI	58
7.11	Valores reais e estimados de k_2 e k_4 - LEA com controle PI	59
7.12	Diagrama de blocos do associação entre a LEA com o controle MPC	60
7.13	Valores estimados dos estados - LEA controle MPC	62
7.14	Resíduos de estimação dos estados - LEA controle MPC	63
7.15	Valores reais e estimados de k_{12} , k_{23} e k_{34} - LEA controle MPC.....	63
7.16	Valores reais e estimados de k_2 e k_4 - LEA controle MPC.....	64
7.17	Sinal dos atuadores - LEA controle MPC	64

7.18	Valores medidos e referência da aplicação de controle MPC com LEA em toda a faixa de operação do sistemas de nível de líquidos	66
7.19	Valores estimados dos estados - LE controle MPC.....	67
7.20	Detalhe dos valores estimados dos estados - LE controle MPC.....	68
7.21	Sinal dos atuadores - LE controle MPC	68

LISTA DE TABELAS

6.1	Algoritmos de Controle Preditivo	44
7.1	Alterações no valor de k_{12}	52
7.2	Alterações no valor de k_{23}	53
7.3	Alterações no valor de k_{34}	53

LISTA DE SÍMBOLOS

Símbolos

A	Área	[m ²]
A_n	Area da secção transversal do tanque n	[cm ²]
C_n	Capacitância do tanque n	[cm ²]
R_{nm}	Resistência do tanque n para o tanque m	[s/cm ²]
h_n	Nível do tanque n	[cm]
H_n	Nível do tanque n no ponto de operacao	[cm]
δh_n	Variacao do nível do tanque n em torno do ponto de operacao	[cm]
q_{nm}	Vazao do tanque n para o tanque m	[cm ³ /s]
Q_{nm}	Vazao do tanque n para o tanque m em regime permanente	[cm ³ /s]
P	Matriz de covariância de estado	
Q	Matriz de covariância do ruído de processo	
R	Matriz de covariância do ruído de medição	
y_k	Sinal medido no instante k	
x_k	Sinal real no instante k	
\hat{x}_k	Sinal estimado no instante k	
\mathbf{x}	Vetor de estados	
$\hat{\mathbf{x}}$	Vetor de estados estimados	
\mathbf{y}	Vetor de saídas do sistema	
\mathbf{w}	Vetor de ruído do processo	

Siglas

ABNT	Associação Brasileira de Normas Técnicas
AGPC	<i>Adaptive Generalized Predictive Control</i>
ARX	<i>Autoregressive with exogenous inputs</i>
CARIMA	<i>Controllerd Auto-Regressive Integrated Moving Average</i>
DMC	<i>Dynamic Matrix Control</i>
FIR	<i>Finite impluse response</i>
FK	Filtro de Kalman
FKE	Filtro de Kalman Estendido
FKU	Filtro de Kalman Unscented
FMP	<i>Following Model Predictive control</i>
GPC	<i>Generalized Predictive Control</i>
GPCI	<i>Generalized Predictive Control with an internal model</i>
GPCT	<i>Generalized Predictive Control with a T-Filter</i>
IHPC	Infinite Horizon Predictive Control
IMC	<i>Internal Model Control</i>
LEA	Linearização Exata Adaptativa
LQMPC	<i>Linear Quadratic optimal Model Predictive Control</i>
MPC	<i>Model Predictive Control</i>
NMPC	<i>Nonlinear Model Predictive Control</i>
PFC	<i>Predictive Funcional Control</i>
UPC	<i>Unified Predictive Control</i>
UT	<i>Unscented Transform</i>

Capítulo 1

Introdução

Este capítulo apresenta a principal motivação desta dissertação de mestrado. Os objetivos são apresentados, visando assim satisfazer um conjunto de características prescritas para este trabalho. Por fim, apresenta-se a estrutura do manuscrito.

1.1 Contextualização

Sistemas dinâmicos industriais e acadêmicos são frequentemente utilizados em conjuntos com controladores, visando torná-los tais sistemas mais rápidos, exatos e confiáveis baseando-se em requisitos específicos de cada caso. No meio acadêmico existem estudos e implementações de diversas técnicas de controle de processos, como controle PID, controle ótimo, controle preditivo, controle robusto, controle por alocação de pólos, controle por modos deslizantes e outras técnicas de controle não-linear.

O controle preditivo juntamente com os controladores Proporcional-Integral-Derivativo (PID) compõem as técnicas de controle mais utilizadas nas indústrias do mundo como apresentam Richalet et al. em [Richalet 1993]. As diversas outras técnicas, como controle H_2 e H_∞ , são mais restritas ao meio acadêmico e estão pouco presentes na engenharia prática e experimental [Qin e Badgwell 1996]. Segundo [Findeisen 2002], dentre as técnicas modernas de controle de processos, somente o Controle Preditivo Baseado em Modelo está presente de forma significativa nas indústrias. Poucas técnicas em Engenharia de Controle gozam do privilégio de estar presente no mundo dos problemas mais práticos, como a indústria, no meio acadêmico e ainda ser uma técnica bastante intuitiva e funcional como o controle preditivo.

As pesquisas associadas às estratégias de controle preditivo não-linear têm apresentado grande crescimento ultimamente, registrando, também, um número considerável de aplicações na indústria. Apesar disso, muitas questões continuam em aberto, especialmente, aquelas associadas à estimação, adaptação, robustez e à otimização.

A representação de um processo complexo através de um modelo não-linear, com o objetivo de melhorar seu desempenho dinâmico, tende a prejudicar a simplicidade de projeto do controlador preditivo. Com o objetivo de unir as vantagens das duas abordagens: a representação da não-

linearidade de um processo com a simplicidade de projeto, propõem-se o uso da linearização exata adaptativa (LEA) ao controle de sistemas não-lineares.

1.2 Definição do problema

A grande maioria dos sistemas encontrados no mundo físico possuem não-linearidades das mais diversas, além de restrições de atuação e medição. Em contrapartida a grande maioria das técnicas de controle de processos são técnicas lineares que, em princípio, deveriam ser aplicadas somente a sistemas lineares. Assim tem-se uma situação complicada: abordagens lineares para processos não-lineares, o que restringe a aplicação a práticos. A aplicação direta de técnicas lineares a sistemas não-lineares é, geralmente, restrita a uma pequena excursão em torno de um ponto de operação do sistema.

O sistema de nível de líquidos do LAVSI (Laboratório de Automação, Visão e Sistemas Inteligentes) é um sistema não-linear multivariável. Este sistema ilustra bem várias das dificuldades da aplicação de técnicas de controle linear a sistemas não-lineares [Bernardes et al. 2006]. Entre as dificuldades de controle pode-se destacar a variação do modelo com o ponto de operação (altura no nível de líquido como será visto no Capítulo 3). Isso pode ser minimizado utilizando-se controle linear de pequenos sinais em pontos de operação, específicos como ilustrado pelo controle no espaço-de-estados apresentado por Freitas et al. [Freitas, Borges e Bauchspiess 2004].

O controle de sistemas não-lineares utilizando controladores lineares projetados para pontos de operação gozam de pouca aplicabilidade, pois são restritos aos pontos para os quais foram projetados. Um controle no ponto de operação do sistema de nível líquidos projetado para níveis baixo, até 10cm , não funciona quando se aplica a outro ponto do mesmo sistema, exemplo referência em 20cm . Assim torna-se complicado a aplicação de técnicas de controle linear para controlar o sistema de nível de líquidos.

A utilização de controle por linearização exata (LE), [Isidori 1989, Sousa 1998], elimina o problema do ponto de operação, permitindo um bom controle em toda a faixa de operação. Outro problema surge em decorrente da aplicação direta da Linearização Exata, a forte dependência de uma estrutura de modelo ‘coerente’ com o processo físico e corretos valores de seus parâmetros. Assim aplicando-se a linearização exata ao processo de nível de líquidos espera-se que seja possível projetar controladores lineares eficientes em toda a faixa de operação do sistema.

Porém mesmo com a linearização exata o sistema de nível de líquido não é controlado de forma simples como apresenta Gosmann em [Gosmann 2002] que realiza a aplicação da linearização exata a um processo de nível multivariável, com três tanques e duas bombas para entrada de líquido. Nessa aplicação nota-se uma grande dependência dos parâmetros do processo para que o controle por linearização exata seja efetivo. Sabe-se que a variação dos parâmetros com o tempo é algo que pode ocorrer neste tipo de processo e assim também afeta a acurácia do controlador.

Neste contexto temos dois pontos importante impossibilidade de projetar um controlador linear que gere resultados satisfatórios em toda a faixa de operação do sistema de nível de líquidos. O segundo ponto é relativa influência da variação paramétrica quando se utiliza a linearização

exata aplicada ao sistema de nível de líquido, assim a simples aplicação da linearização exata não possibilita um controle efetivo do sistema de nível [Gosmann 2002].

1.3 Objetivos do projeto

Esse trabalho propõe a utilização da linearização exata adaptativa, que tem o objetivo de fornecer um modelo linear atualizado, que será utilizado por um controlador preditivo linear ou outra técnica de controle linear. Tem-se assim um controle adaptativo de sistemas não-lineares, onde as não-linearidades do processo são explicitamente consideradas na parte estática do controle do processo e a parte linear dinâmica possibilita a aplicação de técnicas lineares bastante difundidas no meio acadêmico.

A linearização exata elimina a dependência do ponto de operação dos sistemas não-lineares [Sousa 1998] e gera um modelo linear para o controlador. A utilização do filtro de Kalman estendido associado à linearização exata minimizará os erros de modelagem da linearização exata, sendo que este é um dos problemas da linearização exata. Para a validação prática essa estratégia será aplicada ao processo desenvolvido por Bernardes et al. em [Bernardes et al. 2006]. Em [Freitas, Borges e Bauchspiess 2004] o filtro de Kalman estendido (FKE) foi aplicado com sucesso ao sistema de nível de líquidos de terceira ordem apresentado por Gosman em [Gosmann 2002].

A linearização exata adaptativa é a proposta apresentada neste trabalho para controle não-linear. A LEA consiste no uso de um estimador sub-ótimo, um filtro de Kalman estendido, que realiza a estimação de estados e parâmetros do processo melhorando o controle não-linear por linearização exata. Nesta estratégia de controle temos um sistema dinâmico composto por blocos de sistemas SISO, mesmo para um sistema não-linear multivariável, lineares e desacoplados que podem ser controlados com técnicas de sistemas lineares e um bloco de transformação de estados não-linear estático [Sousa 1998, Isidori 1989]. A Figura 1.1 apresenta a estrutura funcional da linearização exata adaptativa.

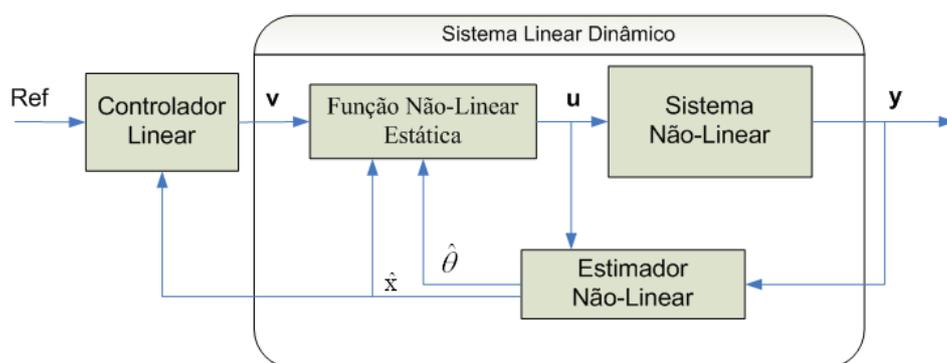


Figura 1.1: Estrutura funcional da linearização exata adaptativa

1.4 Apresentação do Texto

Essa secção apresenta resumidamente o conteúdo dos 7 capítulos seguintes desse trabalho.

Capítulo 2: Estratégias de Controle Não-Linear

No Capítulo 2 é feita uma revisão bibliográfica sobre o tema em estudo, apresenta estudo sobre estimação e controle linear e não-linear. Uma revisão sobre controle de sistemas não-lineares é feito apresentando formas bastante utilizadas, desde a linearização no ponto de operação ao controle não-linear utilizando funções não-lineares no controlador. Inicialmente apresenta-se trabalhos com o foco em estimação, tanto em batelada quanto estimadores recursivos baseados no filtro de Kalman, posteriormente apresenta-se estratégias de controle de sistemas não-lineares, dando-se ênfase em procedimentos que utilizam técnicas de controle linear aplicado a sistemas não-lineares.

Capítulo 3: Sistema de Nível de Líquidos

O Capítulo 3 mostra de forma sucinta o sistema de nível de líquidos não-linear do LAVSI. Este processo possui quatro tanques acoplados com duas entradas de líquidos e duas saídas. A este sistema não-linear a metodologia desenvolvida neste trabalho será aplicada.

Capítulo 4: Estimação Não-Linear Baseada no Filtro de Kalman

O Capítulo 4 apresenta o filtro de Kalman estendido. O FKE permite a aplicação do filtro de Kalman a sistemas não-lineares, o filtro de Kalman(FK) é um estimador recursivo ótimo para sistemas lineares. O FKE é um estimador sub-ótimo para sistemas não-lineares, onde o filtro de Kalman pode ser aplicado a sistemas não-lineares utilizando o respectivo modelo linearizado localmente na propagação da matriz de covariâncias.

Capítulo 5: Linearização Exata Adaptativa

O Capítulo 5 descreve a metodologia empregada no desenvolvimento do projeto da linearização exata adaptativa que faz uso da estimação conjunta de estados e parâmetros pelo FKE, apresentado no Capítulo 4, para adaptar os parâmetros da linearização exata do sistema tornando-a mais robusta e sensível a mudanças durante a execução do controle.

Capítulo 6: Controle Preditivo Baseado em Modelo

O Capítulo 6 apresenta o controle preditivo baseado em modelo (MPC), uma técnica de controle usual para sistemas lineares, aplicado a um sistema não-linear com a linearização exata adaptativa. Assim tem-se uma técnica de controle eficiente para processos não-lineares multivariáveis.

Capítulo 7: Resultados Simulados

Resultados de simulações são discutidos no Capítulo 7 com aplicações da associação entre a linearização exata adaptativa e controle preditivo baseado em modelo e proporcional-integral (PI).

Capítulo 8: Conclusões e Pesquisa Futuras

O Capítulo 8 apresenta as conclusões desse trabalho.

Capítulo 2

Estratégias de Controle Não-Linear

Este capítulo apresenta uma revisão sobre controle e estimação linear de processos não-lineares. Inicialmente apresenta-se a parte de estimação para controle seguida de uma apresentação de algumas implementações de controle para sistemas não-lineares.

Introdução

O controle de sistemas não-lineares é objeto de estudo de diversos trabalhos acadêmicos e industriais. Este capítulo apresentará algumas estratégias de estimação e controle de sistemas não-lineares. Os trabalhos escolhidos são baseados em dissertações de mestrado, teses de doutorado, artigos publicados em periódicos ou recentes conferências. Inicialmente apresenta-se estudos sobre estimação de sistemas lineares e não-lineares utilizando diversas técnicas, como estimação multi-modelos em batelada, estimação recursiva pelo filtro de Kalman e suas derivações não-lineares e trabalhos baseados em estimação recursiva pelo método dos mínimos quadrados. Além disso mostra-se de forma resumida uma estrutura de controle preditivo não-linear com funções não-lineares explicitamente utilizadas na função de custo, além de diversas aplicações de técnicas lineares a sistemas não-lineares, controle preditivo e controle robusto. Técnicas utilizando sistemas inteligentes para controlar e estimar sistemas serão também apresentadas, assim como recentes publicações envolvendo alguma forma de adaptação nos parâmetros da função não-linear estática da linearização exata.

2.1 Estimação para Controle

O trabalho de Schön [Schön 2001] apresenta uma técnica de identificação multi-modelos para aplicação em controle preditivo. Com foco em identificação de sistemas, com o objetivo de utilizar modelos como base para um controlador preditivo. Assim o modelo interno do controlador é identificado de diversas formas em diversos pontos de operação com uso de estimação em batelada.

Neste tipo aplicação tem-se diferentes modelos para os diferentes pontos de operação, como o trabalho trata apenas do problema de identificação para controle preditivo deve-se utilizar o

modelo identificado em cada passo da predição ou utilizar um controlador de escalonamento de ganho.

Bitencourt Junior em [Bitencourt Junior 2003] faz um estudo sobre aplicações do filtro de Kalman como estimador recursivo aplicado a sistemas não-lineares. Nesse estudo além da descrição original do filtro de Kalman outras duas derivações do algoritmo são desenvolvidas para sistemas não-lineares: o filtro de Kalman estendido (EKF) e o Filtro de Kalman Unscented (UKF).

Além da teoria básica de estimadores recursivos, especialmente sobre o filtro de Kalman, Bitencourt Junior apresenta aplicações da estimação recursiva de sistemas não-lineares aplicados ao sistema de Lorenz e ao Circuito de Chua [Aguirre 2004, cap. 15],[Aguirre, Rodrigues e Mendes 1997]. Mostra também que devido às não-lineares do sistema caótico de Chua o UKF apresenta melhores resultados que o EKF pois este utiliza um modelo linearizado na propagação das covariâncias, veja no capítulo 4 seção 4.2, diferente do UKF que utiliza a ‘Transformação Unscented’, proposta por Julier et al. em [Julier, Uhlmann e Durrant-Whyte 2000], para propagação de covariâncias como discutido em [Bitencourt Junior, Torres e Aguirre 2004].

Wan et al. em [Wan, Merwe e Nelson 2000] apresenta o filtro de Kalman *Unscented* como derivação do filtro de Kalman baseado na transformada *Unscented*. O FKU tem-se mostrado uma técnica de estimação de sistemas não-lineares bastante eficaz, principalmente em sistemas que possuem não-linearidades complexas, neste caso o FKU pode-se destacar em relação à aplicação do FKE e mesmo em relação a filtro de partículas [Bølviken et al. 2001], veja Borges e Menezes em [Borges G.A. 2006].

2.2 Controle Preditivo Não-Linear Direto

Os processos industriais devem operar sob especificações de desempenho e segurança, além de um conjunto de restrições. Assim as diversas técnicas de aplicação de controle preditivo a sistemas não-lineares [Findeisen 2002] torna-se uma abordagem interessante. O controle preditivo não-linear direto¹ utiliza o modelo não-linear do processo diretamente na função de custo a ser minimizada. Isto leva a um problema que normalmente não tem solução ótima garantida [Qin e Badgwell]. Assim o controle preditivo não-linear direto fica restrito a problemas onde é possível encontrar uma solução ótima global garantida. Neste contexto é difícil garantir estabilidade e convergência da solução. No caso linear com função de custo quadrática tem-se uma única solução ótima [Rossiter 2003, Camacho e Bordons 2003]. A Figura 2.1 mostra a estrutura do controlador preditivo não-linear apresentada por Findeisen e Allgower em [Findeisen 2002].

A Figura 2.1 apresenta os blocos funcionais do controle preditivo direto aplicado por Findeisen e Allgower: a planta não-linear, um estimador de estados e o controlador preditivo não-linear. Sendo o controlador composto por: um modelo interno da planta, uma função de custo associada a restrições nos estados e um otimizador dinâmico.

¹O termo ‘Controle Preditivo Não-Linear Direto’ é usado neste trabalho para diferenciar do Controle Preditivo Não-Linear baseado em Modelos Lineares, ou seja, este é o tipo de controle que utiliza a função não-linear do sistema de forma explícita na função de custo a ser otimizada.

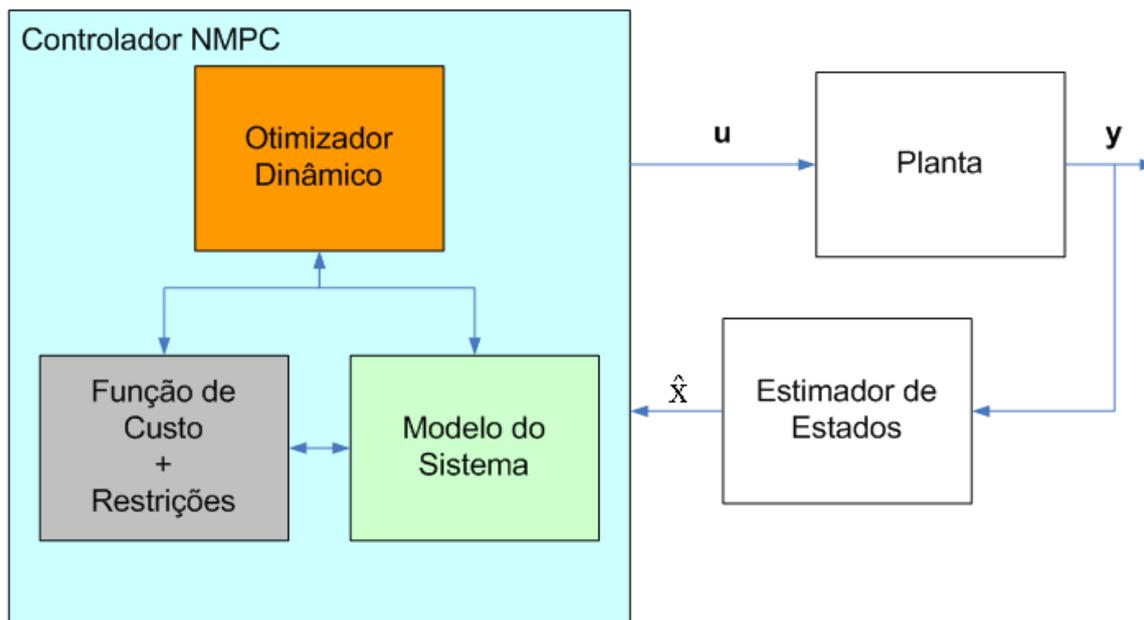


Figura 2.1: Estrutura de Controlador Preditivo Não-Linear apresentado por Findeisen e Allgower [Findeisen 2002]

2.3 Controle Não-Linear Baseado em Modelos Lineares

O trabalho de Pimenta [Pimenta 2003] apresenta um controle preditivo generalizado adaptativo, do inglês *Adaptive Generalized Predictive Control* (AGPC) com base em modelos identificados pelo método dos mínimos quadrado [Isermann R. 1992, Ljung 1999] ou pelo método do gradiente. Note que o modelo deverá ser diferente para cada ponto de predição e assim de forma correspondente será calculado o sinal de controle com o *Generalized Predictive Control* (GPC).

A estimação e a modelagem baseada no filtro de Kalman estendido é outra forma comum de utilização de técnicas lineares de controle preditivo, como o recente trabalho de Bellemans et al. [Bellemans, De Schutter B. e De Moor 2006], que faz a aplicação do FKE para identificação de modelos do processo para uso no controlador linear. Nesse recente trabalho o modelo interno do controlador é alterado a cada instante de amostragem, ou seja, o modelo utilizado é um modelo com estados estimados pelo FKE. Esse modelo é, na verdade o mesmo utilizado na propagação da matriz de covariâncias da estimação recursiva via filtro de Kalman, veja mais detalhes nas Seções 4.1 e 4.2.

Uma abordagem comum em aplicações de controle preditivo linear em sistemas não-lineares é a utilização de modelos de Hammerstein e de Wiener como apresentam os trabalhos de Gomez em [Gomez, Jutan e Baeyens 2004], Bloemen et. al em [Bloemen, Boom e Verbruggen 2000] e Yun em [Yun et al. 2005]. Tais modelos são compostos por dois elementos básicos um modelo dinâmico linear e um bloco estatico não-linear na entrada, no caso dos modelos de Hammerstein, ou na saída, caso de Wiener. Muitos processos podem ser modelados dessa forma [Fruzzeti, Palazoglu e McDonald 1997]. Assim pode-se controlar um sistema não-linear com técni-

cas de controle preditivo linear como apresentado em [Abdenmour M. Ksouri 2002] por Abdenmour e por Cervante et al em [Cervantes, Agamennoni e Figueroa 2003] onde se utilizam técnicas de estimação recursiva com controle preditivo na parte dinâmica linear dos modelos de Hammerstein e Wiener.

Fruzzetti et al. em [Fruzzetti, Palazoglu e McDonald 1997] apresentam um técnica de controle preditivo não-linear que utiliza modelo de Hammerstein, cuja estrutura é ilustrada na Figura 2.2, onde F representa um filtro linear, G_c é o controlador preditivo baseado em modelo, do inglês *Model Predictive Control*, (MPC) linear, NL^I é o elemento estático não-linear, NL^I é a inversa da não-linearidade NL (suas raízes), x é a saída do controlador, y_m é a saída do modelo e h é uma variável auxiliar de forma que $h = y - y_m$.

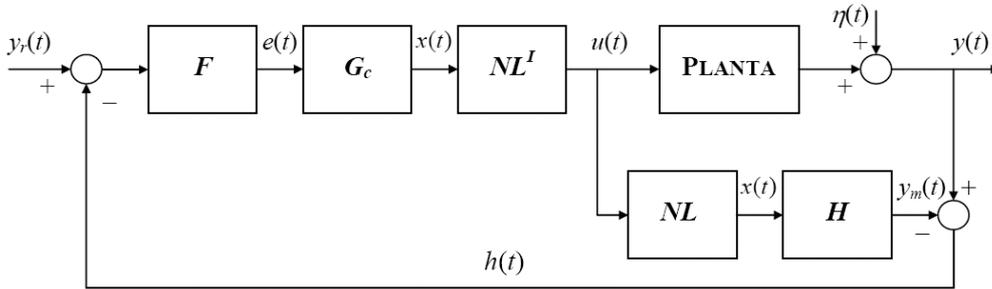


Figura 2.2: Estrutura do Controlador de Fruzzetti

A função custo a ser minimizada é:

$$J_f = \sum_{i=N_1}^{N_2} \Psi e^2(t+i) + \sum_{i=1}^{N_u} \Lambda \Delta x^2(t+i-1), \quad (2.1)$$

onde Ψ e Λ são as respectivas ponderações de $e(t)$ e Δx .

Como a não-linearidade do sistema é representada por uma expansão polinomial finita, a inversa da não-linearidade pode ser representada diretamente utilizando suas raízes. O projeto do controlador preditivo é linear gerando $x(t)$ que, a partir de NLI, gera o sinal de controle, $u(t)$, a ser aplicado na planta. O sinal de controle deve ser selecionado dentre as raízes válidas (valores reais que atendam às restrições) do polinômio de NL, equação (2.1), sendo recomendável que este tenha grau ímpar para garantir pelo menos uma solução real.

O controle linear robusto H_∞ aplicado a sistemas não-lineares foi objeto de estudo da tese de doutorado de Franco [Franco 2006]. Nesse trabalho a aplicação da técnica de controle robusto linear foi utilizada como controlador de um sistema não-linear de levitação magnética a partir da linearização exata robusta apresentada em [Franco et al. 2006].

A principal deficiência da linearização exata clássica ² citada na tese é a dependência desta técnica dos valores dos parâmetros do processo. Um dos objetivos do corrente trabalho é resolver este problema com a adaptação da linearização exata, ver seção de objetivos 1.3.

²Temo utilizado pela autora da tese para diferenciar da linearização robusta proposta em [Franco 2006, Franco et al. 2006]

A linearização exata robusta é uma técnica que produz como resultado um modelo linearizado em cada ponto de operação do processo. Seja o seguinte sistema não-linear:

$$\begin{cases} \dot{x} = f(x) + g(x)u = f(x) + \sum_{i=1}^m g_i(x)u_i, \\ y = \lambda(x), \end{cases} \quad (2.2)$$

um sistema não-linear quadrado, ou seja, como m entradas e m saídas. O modelo utilizado no controle robusto via linearização exata robusta será obtido como uma aproximação linear do sistema 2.2 em torno de x_0 . O resultado da tal aproximação (escolhido, sem perda de generalidade, como $x_0 = 0$) [Franco 2006, cap. 1] é dado por:

$$\begin{cases} \dot{x} = A_r x_r + B_r v_r, \\ y = C_r x, \end{cases} \quad (2.3)$$

onde:

$$A_r = \left. \frac{\partial f}{\partial \mathbf{x}} \right|_{x=0}, \quad (2.4)$$

$$B_r = g(0), \quad (2.5)$$

$$C_r = \left. \frac{\partial \lambda}{\partial \mathbf{x}} \right|_{x=0}, \quad (2.6)$$

note que o sinal de controle utilizado é v_r e não u_r , ou seja, este não é o sinal que será aplicado no processo não-linear, pois se fosse aplicado este diretamente no processo tem-se a linearização no ponto de operação. Em [Franco et al. 2006] apresenta-se a transformação necessária para mudar o sinal de atuação do modelo linear para o sinal de atuação a ser enviado para o processo não-linear. Novamente ressalta-se o grande interesse acadêmico na utilização de técnicas lineares aplicadas a sistemas não-lineares.

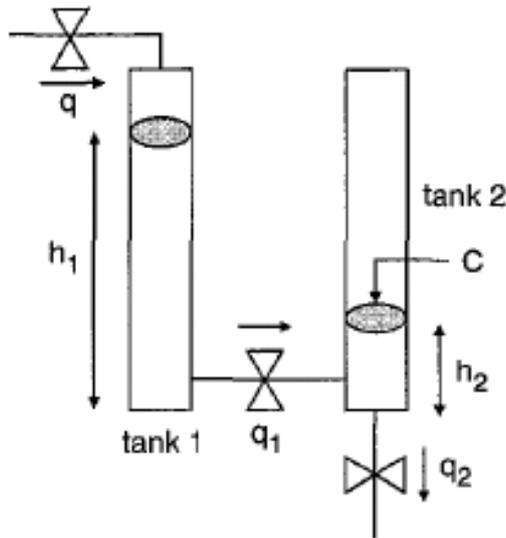


Figura 2.3: Sistema de dois tanques acoplados apresentado Poulsen et al.

A aplicação de controle preditivo linear em sistema não-linear de nível de líquidos foi objeto de estudo do trabalho apresentado por Poulsen em [Poulsen, Kouvaritakis e Cannon 2001]. Nesse

trabalho foi utilizado um sistema de nível de líquidos com dois tanque acoplados, como mostrado na Figura 2.3. A equação 2.7 apresenta um modelo modificado do sistema, onde os nível dos tanques h_1 e h_2 são as variáveis de estado do sistema não-linear e a saída do sistema é o nível do tanque 2, $y = h_2$, os tanques estão acoplados por uma válvula pela qual passa um fluxo dependente da diferença de nível. A saída de líquido do sistema ocorre pelo tanque 2, que também é função do nível neste tanque, $q_o = k_2\sqrt{h_2}$. Assim tem-se o seguinte modelo não-linear do sistema:

$$\begin{cases} \dot{h}_1 &= q_i - k_{12}\sqrt{h_1 - h_2} \\ \dot{h}_2 &= k_{12}\sqrt{h_1 - h_2} - k_2\sqrt{h_2} \end{cases} \quad (2.7)$$

A aplicação da linearização exata foi empregada para possibilitar a aplicação do controle linear ao sistema. O controle MPC com restrições aplicado no modelo fornecido pela Linearização Exata do modelo mostrado em 2.7 foi implementado e comparado a um controlador PID para aplicações em pequenos sinais como apresentado na secção de resultados do trabalho [Poulsen, Kouvaritakis e Cannon 2001]. Vale ressaltar que este processo é um sistema SISO e que o controlador não possui característica antecipativa. Assim, a equação estática da linearização exata é:

$$\Phi(u, h) = (\alpha_1 u_t + \alpha_2)\sqrt{h_1 - h_2} + \alpha_3\left(\frac{h_1 - h_2}{h_2} - 1\right)\sqrt{h_2}, \quad (2.8)$$

onde:

$$\alpha_1 = \frac{2C}{a_2}, \quad (2.9)$$

$$\alpha_2 = C\left(2a_2 - \frac{a_1^2}{a_2}\right)e \quad (2.10)$$

$$\alpha_3 = a_1 C, \quad (2.11)$$

para maiores detalhes de como a equação (2.8) foi encontrada ver texto original de Poulsen et al. em [Poulsen, Kouvaritakis e Cannon 2001].

A equação (2.7) foi adaptada para a forma de modelagem utilizada nesse trabalho, pois os autores não trabalham a notação compacta com k_2 e k_{12} . Logo no texto original tem-se que:

$$k_{12} = \sigma_1 a_1 \sqrt{2g}, \quad (2.12)$$

$$k_2 = \sigma_0 a_0 \sqrt{2g}, \quad (2.13)$$

onde:

$$a_0 = 0,8\text{cm}^2 \quad (2.14)$$

é a área da secção transversão da conexão entre os tanques,

$$a_1 = 0,5\text{cm}^2 \quad (2.15)$$

é a área da secção transversão da conexão de saída do tanque 2 e

$$C = 153,9\text{cm}^2 \quad (2.16)$$

é a área da secção transversal dos tanques 1 e 2. Assim substituindo os valores de k_{12} e k_2 , equações (2.12) e (2.13), na equação 2.7 tem-se o modelo original [Poulsen, Kouvaritakis e Cannon 2001].

2.4 Controle Não-Linear via Sistemas Inteligentes

As redes neurais artificiais são aproximadores universais, como a lógica fuzzy [Ljung 1999], [Haykin 2001] e [Hangos, Bokor e Szederkényi 2004]. As redes neurais são aplicadas em engenharia de controle tanto na identificação quanto no controle de sistemas não-lineares [Haykin 2001, Haykin 2001, Huang e Lewis 2003]. O controle preditivo utilizando redes neurais artificiais é bastante comum como mostram os recentes trabalhos de Peng et al. [Peng, Nakano e Shioya 2007], Kishor e Singh [Kishor e Singh 2007] e Smith e Hashtrudi-Zaad [Smith e Hashtrudi-Zaad 2005]. A lógica fuzzy bem como sistemas neuro fuzzy são freqüentemente utilizados em sistemas de controle seja para identificar ou mesmo como controlador de processos não-lineares [Lu e Tsai 2007].

Peng et. al em recente trabalho [Peng, Nakano e Shioya 2007] apresentam uma estrutura mista com redes neurais de base radial (RBF), acrônimo do inglês ‘radial basis function’, com linearização local baseada em modelos auto-regressivo com entradas exógenas (ARX), acrônimo do inglês ‘*autoregressive with exogenous inputs*’, para descrever a dinâmica de processos industriais que possuem não-linearidades suaves e não-estacionárias. Essa estrutura permite o tratamento de processos variantes no tempo e dependentes do ponto de operação, desde que tenham localmente um comportamento linear, tendo assim um modelo RBF-ARX, associação entre redes neurais de base radial e um modelo auto-regressivo com entradas exógenas.

O modelo RBF-ARX é um modelo pseudo-linear previamente identificado, a rede de base radial servirá para definição do ponto de operação, atuando como um escalonador de ganho. Em [Peng, Nakano e Shioya 2007] apresenta-se também um controlador preditivo não-linear baseado no modelo RBF-ARX, além disso discute-se a estabilidade do controlador não-linear sob certas circunstâncias. A praticidade e eficácia desse controlador, assim como as melhorias, são demonstradas com uma aplicação industrial ao processo de decomposição do óxido do nitrogênio (NO_x) em plantas térmicas.

2.5 Linearização Exata Adaptativa

Os trabalhos de [Zhang e Singh 2001] e [Ko, Strganac e Kurdila 1999] fazem aplicações de linearização exata adaptativa em sistemas não-lineares. Esses trabalhos apresentam aplicações de linearização exata com estimadores recursivos para adaptação dos parâmetros.

Diferentemente do presente trabalho aqueles autores não aplicam técnicas de controle preditivo nem utilizam o filtro de Kalman na estimação dos parâmetros. Este dois trabalhos têm foco na linearização exata adaptativa associada a estimadores recursivos de estados e parâmetros. Neste

trabalho o foco será a associação do filtro de Kalman com a linearização exata que possibilita aplicação de técnicas de controle linear a sistemas não-lineares.

2.6 Resumo do Capítulo

O foco deste capítulo foi mencionar trabalhos recentes onde houve a aplicação de técnicas e aplicações recentes de controle de sistemas não-lineares, principalmente aplicações de métodos lineares. A seção 2.1 apresentou trabalhos com foco em técnicas de estimação iniciando com um trabalho de estimação em batelada. Apresentou também trabalhos de estimação baseados no filtro de Kalman e suas derivações, assim mostrou-se a importância acadêmica dos estudos de identificação de sistemas e de estimação de estados e parâmetros com o filtro de Kalman estendido e com o filtro de Kalman ‘unscented’, sendo que também foi apresentada a origem da transformação ‘unscented’ que permite a propagação das covariâncias do filtro de Kalman de forma não-linear.

A seção seguinte mostrou alguns trabalhos de controle preditivo utilizando funções não-lineares diretamente no cálculo da função de otimização. A seção 2.3 apresentou o contexto principal deste trabalho: a aplicação de técnicas de controle linear em sistemas não-lineares. Inicialmente mencionou-se uma tese de doutorado onde estimadores recursivos associados a GPC foi utilizado para controlar juntas robótica de forma adaptativa. Foi citado um recente trabalho que utiliza o FKE como estimador recursivo de estados e de modelo linearizado como modelo interno de um controlador preditivo.

Outros trabalhos que utilizam modelos de Hammerstein e Wiener foram apresentados como forma de aplicar o conhecimento de controle linear em sistemas não-lineares, tendo um modelo dinâmico linear e uma função não-linear estática.

A linearização exata robusta proposta em [Franco et al. 2006] como técnica capaz de gerar sistemas lineares para aplicação de controladores lineares robustos mostra o recente interesse acadêmico pela aplicação de técnicas lineares a sistemas não-lineares como abordagem de controle de processos.

Ao final da seção foi mostrado o trabalho [Poulsen, Kouvaritakis e Cannon 2001] desenvolvido por Poulsen et al. onde utiliza-se linearização exata associada a controle preditivo baseado em modelo linear para controlar um sistema de nível SISO, processo de dois tanques acoplados. Poulsen et al. trabalha com um sistema onde as válvulas não são modificadas durante a operação e compara resultados de controle preditivo baseado em modelo como controle proporcional, integral e derivativo em grandes sinais utilizando degrau de 20 cm de altura para a referência.

A seção 2.4 citou alguns trabalhos de redes neurais e lógica fuzzy no controle preditivo de sistemas não-lineares, a seção seguinte mencionou alguns trabalhos de linearização exata com adaptações nos parâmetros da função não-linear, estimados de forma recursiva.

2.7 Conclusões

Atualmente técnicas de controle não-linear de diversas formas estão em estudo por pesquisadores, mas a aplicação de técnicas de controle linear em sistemas reais ainda é uma realidade em pesquisa, como foi apresentado neste capítulo, assim pode-se concluir que técnicas como a linearização exata adaptativa possui expressivo interesse para aplicações práticas de controle de processos.

Capítulo 3

Sistema de Nível de Líquidos

Este capítulo apresenta o sistema multivariável de nível de líquidos do laboratório LAVSI-UnB. Um processo de quatro tanques, duas entradas e duas saídas, onde o quarto tanque possui secção transversal variável a partir de um terço da altura total.

Introdução

O processo de nível de líquidos do LAVSI mostrado na Figura 3.1, é composto por quatro tanques acoplados e duas entradas e duas saídas de líquido conforme esquematizado na Figura 3.2. Pode-se observar que o tanque 1 possui alimentação de líquido através da entrada 1, u_1 , e está acoplado ao tanque 2 por uma válvula regulável. O tanque 2 possui saída de líquido através de uma válvula de saída e está acoplado ao tanque 3 por uma válvula regulável. O tanque 3 possui alimentação de líquido através da entrada 2, u_2 , e está acoplado ao tanque 4 por uma válvula regulável.

As variáveis de estado são as alturas de líquido nos tanques, h_1 , h_2 , h_3 e h_4 . As variáveis manipuladas são as vazões das bombas 1 e 2, q_{i1} e q_{i2} , respectivamente. Nesta configuração tem-se um sistema multivariável de quarta ordem. As entradas de líquidos q_{i1} e q_{i2} estão conectadas nos tanques 1 e 3, respectivamente. As variáveis controladas são as alturas dos níveis dos tanque 2 e 4, respectivamente h_2 e h_4 .

O sinal de controle do sistema pode assumir tanto valores positivos quanto negativos, como apresentado por Bernardes et al. em [Bernardes et al. 2006]. Isso ocorre porque para cada entrada tem-se duas bombas uma para colocar e outra para retirada de líquido nos tanques 1 ou 3, veja as equações do sistema não-linear em 3.3. Onde pode-se observar as entradas influenciado as variáveis h_1 e h_3 .

Com isso pode obter diversas configurações de sistemas SISO, MIMO ou MISO, dependendo das saídas desejadas, escolhidas dentre as variáveis de estado: h_1 , h_2 , h_3 e h_4 . Neste trabalho apresenta-se principalmente a configuração multivariável com as variáveis de saída sendo as alturas nos tanques 2 e 4, tem-se assim um sistema com duas entradas e duas saídas, veja equações (3.3).

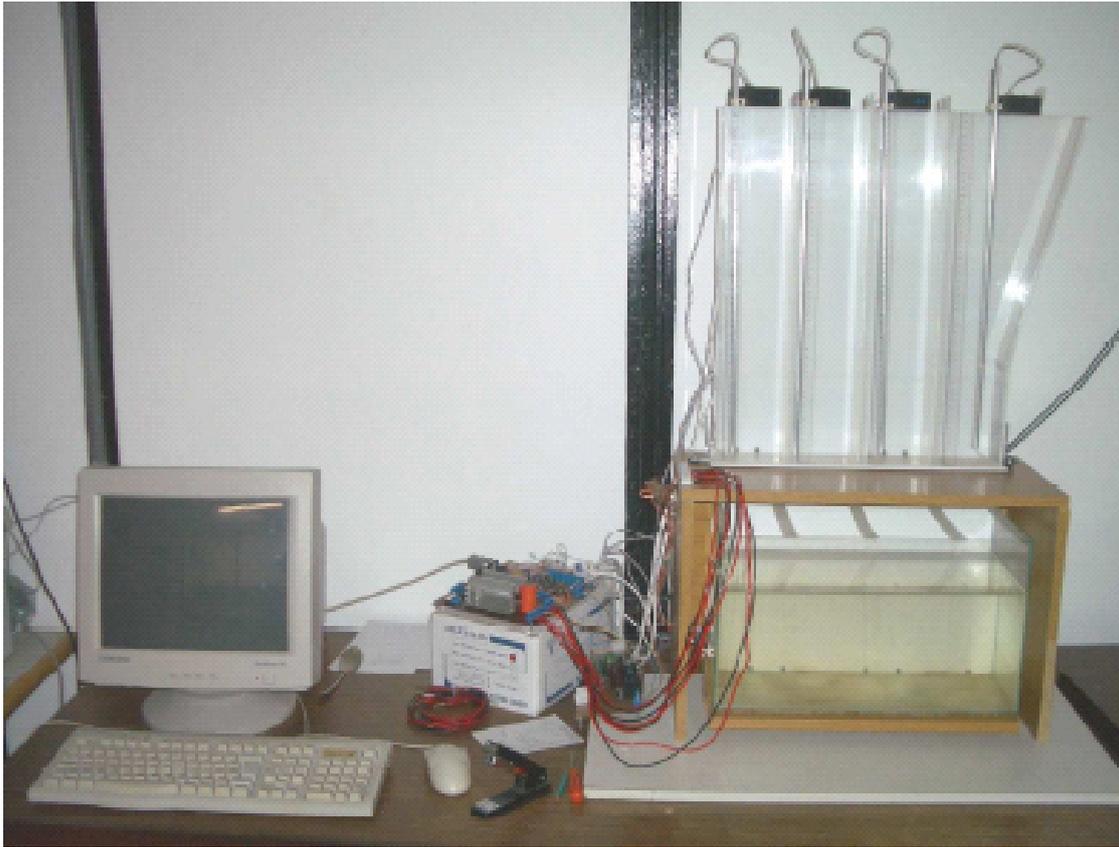


Figura 3.1: Imagem do Processo de Nível de Líquidos

3.1 Modelo Não-Linear

A modelagem matemática de um sistema físico muitas vezes é realizada utilizando-se simplificações para permitir simulações e o estudo dos sistemas dinâmicos. Para a modelagem do sistema de nível de líquidos assumem-se as seguintes simplificações:

1. A água é incompressível;
2. A perda de carga nos dutos que transportam água é nula;
3. O fluxo de saída é turbulento $(k\sqrt{h})$ ¹
4. A variação no nível de tanque é dada pela diferença entre entrada e saída de líquidos naquele tanque. A equação 3.1 mostra essa relação
5. A equação de Bernoulli é válida;

Assim pode-se utilizar a seguinte expressão:

$$\frac{dv}{dt} = A \frac{dh}{dt} = \sum q_i - \sum q_o, \quad (3.1)$$

¹O fluxo de saída turbulento pode ser descrito por $q_o = k\sqrt{h}$. De fato, para uma modelagem mais precisa teríamos que adotar $q_o = k(h)\sqrt{h}$. Para fluxo laminar teríamos que adotar $q_o = k \cdot h$

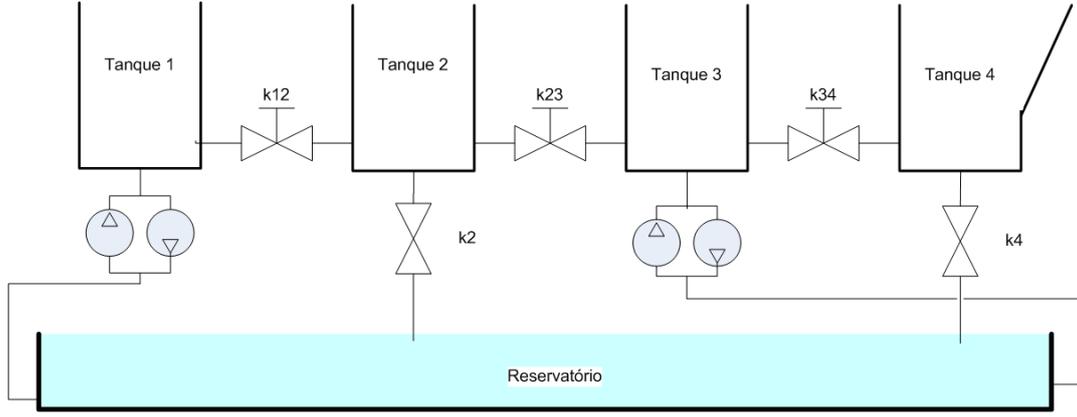


Figura 3.2: Esquemático do Processo de Nível de Líquidos

para obter a variação do volume em um determinado tanque, onde:

- v - volume de líquido no tanque em cm^3 ;
- A - área da secção transversal do tanque em cm^2 ;
- h - o nível de líquido no tanque em cm ;
- q_i - a vazão de entrada no tanque em cm^3/s ;
- q_o - a vazão de saída do tanque em cm^3/s ;

A equação que determina a vazão de saída de líquido pode ser obtida como consequência da aplicação da equação de Bernoulli. Podemos também simplificar tal resultado e colocar apenas um parâmetro, k , e assim a vazão em função da altura resulta em:

$$q = k \cdot \sqrt{h}, \quad (3.2)$$

onde o parâmetro k depende de diversos fatores como a geometria de válvula e da aceleração da gravidade, sua dimensão é $\text{cm}^{2.5}/\text{s}$.

Utilizando as simplificações aqui apresentadas pode-se obter o seguinte modelo não-linear para o sistema de nível de líquidos de quarta ordem:

$$\begin{cases} A_1 \dot{h}_1 = q_{i1}(t) - q_{12}(t)\text{signal}(h_1(t) - h_2(t)) - q_{o1}(t) \\ A_2 \dot{h}_2 = q_{12}(t)\text{signal}(h_1(t) - h_2(t)) - q_{23}(t)\text{signal}(h_2(t) - h_3(t)) - q_{o2}(t) \\ A_3 \dot{h}_3 = q_{i3}(t) + q_{23}(t)\text{signal}(h_2(t) - h_3(t)) - q_{34}(t)\text{signal}(h_3(t) - h_4(t)) - q_{o3}(t) \\ A_4 \dot{h}_4 = q_{34}(t)\text{signal}(h_3(t) - h_4(t)) - q_{o4}(t) \end{cases} \quad (3.3)$$

O modelo apresentado pelas equações (3.3) considera saída de líquidos em todos os tanques, como no tanque 1 e 3 temos entrada de líquidos pode-se simplificar o modelo considerando apenas

o sinal de atuação nos tanques 1 e 3. Na verdade nestes tanques não existe saída de líquidos, como mostra [Bernardes et al. 2006], o que ocorre é uma saída pela conexão das bombas de entrada e retirada de líquido. Assim obtém-se o modelo:

$$\begin{cases} A_1 \dot{h}_1 = q_1(t) - q_{12}(t) \cdot \text{signal}(h_1 - h_2) \\ A_2 \dot{h}_2 = q_{12}(t) \cdot \text{signal}(h_1 - h_2) - q_{23}(t) \cdot \text{signal}(h_2 - h_3) - q_{o2}(t) \\ A_3 \dot{h}_3 = q_{i3}(t) + q_{23} \cdot \text{signal}(h_2 - h_3) - q_{34}(t) \cdot \text{signal}(h_3 - h_4) \\ A_4 \dot{h}_4 = q_{34}(t) \cdot \text{signal}(h_3 - h_4) - q_{o4}(t), \end{cases} \quad (3.4)$$

onde:

- A_i - área da secção transversal do tanque i em cm^2 em função do nívelno respectivo tanque,
- h_i - o nível no tanque i em cm,
- q_{i1} - a vazão de entrada (positiva ou negativa) de líquido no tanque 1 em cm^3/s ,
- q_{i3} - a vazão de entrada (positiva ou negativa) de líquido no tanque 3 em cm^3/s ,
- q_{o2} - a vazão de saída de líquido do tanque 2 em cm^3/s ,
- q_{o4} - a vazão de saída de líquido do tanque 4 em cm^3/s ,
- q_{12} - a vazão entre os tanques 1 e 2 em cm^3/s ,
- q_{23} - a vazão entre os tanques 2 e 3 em cm^3/s ,
- q_{34} - a vazão entre os tanques 3 e 4 em cm^3/s ,
- A função signal é definida da seguinte forma:

$$\text{signal} = \begin{cases} 1, & \text{se } x \geq 0 \\ -1, & \text{se } x < 0. \end{cases} \quad (3.5)$$

A área da secção transversão do tanque 4 sofre variação com o nível, mas as áreas dos tanques 1, 2 e 3 podem ser consideradas constante e iguais a: 60cm^2 . Para o tanque 4 até o nível de $14,7\text{cm}$ a área da secção transversal é de 60cm^2 após este nível a área sofre aumento linear com o nível do líquido como mostra a equação²

$$A_4 = \begin{cases} 60\text{cm}^2 & \forall h_4 < 14,7\text{cm} \\ \left((h_4 - 14,7) \frac{20,2 - 10}{49,5 - 14,7} + 10 \right) \cdot 6 & \forall h_4 \geq 14,7\text{cm}. \end{cases} \quad (3.6)$$

²Os valores indicados na fração $\frac{20,2 - 10}{49,5 - 14,7}$ representam as seguintes características:

- 10 - a menor largura do tanque,
- 20,2 - largura do tanque 4 na altura máxima,
- 14,7 - altura onde se inicia a variação de largura,
- 49,5 - altura máxima do tanque.

A equação 3.6 mostra que o tanque 4 do sistema de nível de líquidos do LAVSI possui uma secção transversal variável quando a altura passa de 14,7 cm. A área da secção transversal tem valor mínimo de 60cm², e atinge o valor de 121,2 cm² quando o nível do tanque é de 49,5 cm. Este tanque possui como análogo elétrico um capacitor cuja capacitância é variável.

A variação da área da secção transversal gera um sistema que precisa de uma adaptação no controle para o nível, pois a linearização do modelo em um ponto com o ponto de operação do sistema não é satisfatória.

Utilizando a equação (3.2) pode-se obter os valores das vazões entre os tanques do modelo não-linear, equação (3.3), obtendo as equações:

$$q_{o2} = k_{o2}\sqrt{h_2(t)}, \quad (3.7)$$

$$q_{o4} = k_{o4}\sqrt{h_4(t)}, \quad (3.8)$$

$$q_{12} = k_{12}\sqrt{|h_1(t) - h_2(t)|}, \quad (3.9)$$

$$q_{23} = k_{23}\sqrt{|h_2(t) - h_3(t)|}, \quad (3.10)$$

$$q_{34} = k_{34}\sqrt{|h_3(t) - h_4(t)|}, \quad (3.11)$$

substituindo-se os valores das equações (3.7) a (3.11) na equação (3.4) temos o seguinte modelo não-linear:

$$\left\{ \begin{array}{l} A_1\dot{h}_1 = q_{i1}(t) - k_{12}\sqrt{|h_1 - h_2|}\text{signal}(h_1 - h_2) \\ A_2\dot{h}_2 = k_{12}\sqrt{|h_1 - h_2|}\text{signal}(h_1 - h_2) \dots \\ \quad - k_{23}\sqrt{|h_2 - h_3|}\text{signal}(h_2 - h_3) - k_{o2}\sqrt{h_2} \\ A_3\dot{h}_3 = q_{i2}(t) + k_{23}\sqrt{|h_2 - h_3|}\text{signal}(h_2 - h_3) \dots \\ \quad - k_{34}\sqrt{|h_3 - h_4|}\text{signal}(h_3 - h_4) \\ A_4\dot{h}_4 = k_{34}\sqrt{|h_3 - h_4|}\text{signal}(h_3 - h_4) - k_{o4}\sqrt{h_4} \end{array} \right. \quad (3.12)$$

3.2 Limitações de Atuação e Referências

O atuador do sistema de nível de líquidos é um conjunto formado por duas moto-bombas, assim tem-se um sinal de atuação positivo e negativo. Porém nem todo par R_2, R_4 de referências do nível h_2 e h_4 é realizável com as limitações Q_{+i1} e Q_{+i2} , estes são os máximos valores das entradas q_{i1} e q_{i2} , respectivamente. Define-se também os valores mínimos das entradas q_{i1} e q_{i2} como: Q_{-i1} e Q_{-i2} , respectivamente.

Nesta seção analisa-se duas possibilidades a referência para o tanque 2 é maior que a referência para o tanque 4, definidos respectivamente como r_1 e r_2 e o caso contrário, onde referência para o

tanque 4 é maior que a referência para o tanque 2. No primeiro caso temos que:

$$q_{o1} = k_2\sqrt{R_2}, \quad (3.13)$$

$$q_{o2} = k_4\sqrt{R_4}, \quad (3.14)$$

assim podemos encontrar os níveis dos tanques 2, 3 e 4 em regime permanente, definidos como: H_2 , H_3 e H_4 . logo:

$$H_2 = R_3, \quad (3.15)$$

$$H_4 = R_4, \quad (3.16)$$

$$H_3 = \frac{k_4^2 H_4}{k_{34}^2} + H_4, \quad (3.17)$$

assim tem-se os seguintes sinais de atuação em regime permanente, Q_{i1} e Q_{i2} , que podem ser facilmente derivados das equações (3.7) a (3.11) e o modelo, equação (3.12):

$$Q_{i1} = k_2\sqrt{H_2} + \text{signalal}(h_2 - h_3)k_{23}\sqrt{|H_2 - H_3|}, \quad (3.18)$$

$$Q_{i2} = k_4\sqrt{H_4} - \text{signalal}(h_2 - h_3)k_{23}\sqrt{|H_2 - H_3|}, \quad (3.19)$$

onde $k_{23}\sqrt{|H_2 - H_3|}$ é o valor de vazão que flui do tanque 2 para o tanque 3, caso a referência r_1 seja maior que r_2 , caso contrário o fluxo se dará do tanque 3 para o tanque 2.

Assim, para que o controle com referências R_2 e R_4 seja exequível, deve-se observar as seguintes restrições de atuação:

$$Q_{-i1} \leq Q_{i1} \leq Q_{+i1}, \quad (3.20)$$

$$Q_{-i2} \leq Q_{i2} \leq Q_{+i2}, \quad (3.21)$$

no sistema de nível atual os valores de vazão máxima e mínima são, respectivamente: $75\text{cm}^3/\text{s}$ e $-80\text{cm}^3/\text{s}$ para ambas as entradas, como mostrado em [Bernardes et al. 2006].

Assim caso os valores de Q_{i1} e Q_{i2} , para um dado par de referências, não estejam dentro dos intervalos indicados nas equações (3.20) e (3.21) o par de referências não será atingível devido a restrições de atuação.

3.3 Conclusões

Este capítulo apresentou o sistema de nível de líquidos do Laboratório de Automação Visão e Sistemas Inteligentes. Sistema este que possui válvulas configuráveis entre tanques interconectados gerando um sistema não-linear multivariável que pode ser objeto de estudo e aplicação de técnicas de controle de sistemas não-lineares. Uma das grandes vantagens deste sistema é a possibilidade de configurações das válvulas entre os tanques.

O sistema é configurável e pode-se ser aplicado a estudos de controle em diversas formas, desde controle de sistema SISO de primeira e segunda ordem a controle multivariável de quarta ordem

com duas entradas e duas saídas. Além disso pode-se realizar comparações entre algoritmos de controle e de estimação aplicados a sistemas não-lineares. Outra vantagem é a fácil configuração das válvulas entre os tanques e a possibilidade de mudança durante a execução de um experimento.

Apresentou-se também uma análise das limitações de atuação para um para qualquer de referências dos níveis dos tanques 2 e 4. Mostrando assim mais uma das dificuldades de controle do sistema na configuração multivariável com as saídas sendo os níveis dos tanques 2 e 4.

Capítulo 4

Estimação Não-Linear Baseada no Filtro de Kalman

Este capítulo apresenta a estimação conjunta de estados e parâmetros do modelo do processo pelo filtro de Kalman Estendido. O FKE é um estimador recursivo sub-ótimo de sistemas não-lineares bastante utilizado em estimação e controle de processos. O FKE é responsável pela parte adaptativa da linearização exata adaptativa, onde os estados e parâmetros são estimados de forma recursiva.

Introdução

O controle de processos pode ser realizado com diversas técnicas, algumas delas exigem um modelo de processo acurado, seja em tempo de projeto ou de execução, como controle adaptativo, controle ótimo e controle preditivo. A obtenção de um modelo para o processo pode ser feita pelas leis física, também denominada modelagem caixa branca, pela identificação caixa preta e pela identificação caixa cinza [Aguirre 2004].

A modelagem caixa branca é baseada num modelo matemático do processo baseado na aplicação de leis físicas que atuam no sistema a ser modelado. A modelagem caixa preta utiliza somente padrões de entrada e saída do processo numa estrutura predefinida, não baseado na modelagem física do processo [Ljung e Glad 1994], e ajusta os parâmetros deste modelo. A identificação caixa cinza é um meio-termo entre a identificação caixa branca que tem o modelo totalmente baseado em leis físicas e a caixa preta, onde desconhece-se o processo em estudo, assim inclui-se termos baseados no processo e outros genéricos [Aguirre 2004]. Em qualquer tipo de modelagem pode-se estimar os parâmetros do modelo com a finalidade de melhorar o modelo para ser utilizado no controle do processo [Ljung 1999].

O modelo de um sistema físico pode assumir diversas formas [Rossiter 2003, Ljung 1999], como *Finite impulse response* (FIR), *Controllerd Auto-Regressive Integrated Moving Average* (CARIMA), funções de transferência, espaço-de-estados e outras formas de modelagem de sistemas.

Este trabalho utilizará o modelo no espaço-de-estados tanto para as equações não-lineares quanto para as linearizadas e lineares. Quando se tem um modelo definido pode-se utilizar técnicas de estimação para obter os valores de dos parâmetros modelados. Neste trabalho utilizamos o filtro de Kalman e suas derivações como estimadores recursivos para estados e parâmetros do modelo.

As técnicas de estimação podem ser utilizadas em identificação de sistemas [Aguirre 2004], sendo assim, uma de suas etapas, para estimar os valores dos parâmetros de um modelo de processo utilizando os dados medidos, técnica básica para aplicação de controladores adaptativos. Outra aplicação é a estimação de variáveis de estado de sistemas dinâmicos, isso com o objetivo de melhorar a medida de tais variáveis que podem estar sob influência de ruído ou mesmo para estimar uma variável que não pode ser medida diretamente.

A estimação recursiva fornece novas estimativas, para as variáveis de estados ou para os parâmetros do modelo, a cada iteração do algoritmo. Aguirre em [Aguirre 2004] apresenta aplicações de técnicas de estimação recursiva de sistemas lineares e não-lineares. A estimação utilizada neste trabalho utiliza apenas os valores medidos, as entradas do processo e as estimativas na iteração anterior para gerar novas estimativas das variáveis de estados e dos parâmetros do processo, ou seja, estimação conjunta de variáveis e parâmetros do modelo utilizando o filtro de Kalman estendido.

4.1 O Filtro de Kalman - FK

O filtro de Kalman é um estimador recursivo ótimo para sistemas lineares e variantes no tempo [Kalman 1960] que foi desenvolvido por Rudolf Kalman em 1960. Isso significa que a estimação do vetor de estado é realizada com o valor previamente estimado e com as medidas atuais, em contraste com os métodos de estimação em batelada. Nestes são necessários valores históricos de observações ou valores estimados. O FK não só funciona muito bem na prática como é uma solução teoricamente elegante porque é possível mostrar que de todas as possibilidades de filtragem o FK é a solução que minimiza a variância do erro estimação[Simon 2006].

O filtro de Kalman é provavelmente o estimador quadrático recursivo mais utilizado em engenharia de controle. Uma forma de utilização bastante comum é a estimação de estados e parâmetros de um sistema, estimação conjunta, que pode ser feita simultaneamente ou de forma desacoplada [Jazwinski 1970]. O trabalho original de Kalman [Kalman 1960] era restrito para sistemas modelados em tempo discreto. No ano seguinte Kalman e Bucy [Kalman e Bucy 1961] desenvolveram uma versão do filtro de Kalman para o caso contínuo, neste caso o filtro também é conhecido como filtro de Kalman-Bucy.

A estimação de sistemas utilizando o filtro de Kalman é realizada em duas fases, a primeira é denominada predição, equações 4.7-4.9, e a segunda correção, equações 4.10 e 4.11. Na predição utiliza o modelo linear do processo, os estados estimados na iteração anterior, quando for o caso da estimação conjunta os parâmetros anteriormente estimados e a entrada do processo no instante atual, assim obtém-se os estados ou estados e parâmetros preditos.

Na fase de correção utiliza-se as medições do processo para realizar uma ponderação entre a predição e a medição, assim tem-se os valores estimados pelo filtro ótimo para sistemas lineares. A

inicialização gera os valores iniciais da estimação \hat{x}_0 e da matriz de covariância do erro de estimação P_0 , ver as equações 4.5-4.6.

4.1.1 Algoritmo do filtro de Kalman

Este é o algoritmo básico do filtro de Kalman para sistemas discreto [Kalman 1960]. As fases de inicialização, predição e correção são apresentadas para o sistema descrito pela equação 4.1

Seja o seguinte sistema linear, modelado no espaço-de-estados:

$$\begin{cases} \mathbf{x}_{k+1} = \mathbf{F}_k \mathbf{x}_k + \mathbf{B}_k \mathbf{u}_k + \mathbf{w}_{k+1}, \\ \mathbf{y}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k, \end{cases} \quad (4.1)$$

onde \mathbf{w}_k e \mathbf{v}_k são ruídos Gaussianos independentes de média nula e matrizes de covariâncias \mathbf{Q}_k e \mathbf{R}_k , respectivamente, ou seja,

$$\mathbf{w}_k \sim N(0, \mathbf{Q}_k), \quad (4.2)$$

$$\mathbf{v}_k \sim N(0, \mathbf{R}_k). \quad (4.3)$$

Sendo que \mathbf{w}_k é o ruído de processo e \mathbf{v}_k é o ruído de medição do sistema modelado no espaço-de-estados.

Inicialização:

$$k = 0, \quad (4.4)$$

$$\hat{\mathbf{x}}_0 = E[\mathbf{x}_0], \quad (4.5)$$

$$\mathbf{P}_0 = E[(\mathbf{x}_0 - E[\mathbf{x}_0])(\mathbf{x}_0 - E[\mathbf{x}_0])^T]. \quad (4.6)$$

Fase de predição da estimação:

$$\hat{\mathbf{x}}_k^- = \mathbf{F}_{k|k-1} \hat{\mathbf{x}}_{k-1} + \mathbf{B}_{k|k-1} \mathbf{u}_k. \quad (4.7)$$

Propagação da matriz de covariância do erro de estimação:

$$\mathbf{P}_k^- = \mathbf{F}_{k|k-1} \mathbf{P}_{k-1} \mathbf{F}_{k|k-1}^T + \mathbf{Q}_{k-1}. \quad (4.8)$$

A matriz de ganho de Kalman é definida como:

$$\mathbf{K}_k = \mathbf{P}_k \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_k \mathbf{H}_k^T + \mathbf{R}_k). \quad (4.9)$$

Fase de correção do valor predito

$$\hat{\mathbf{x}}_k^+ = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{y}_k - \mathbf{H}_k \hat{\mathbf{x}}_k^-). \quad (4.10)$$

Atualização da matriz de covariância do erro de estimação

$$\mathbf{P}_k^+ = (I - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k^-. \quad (4.11)$$

4.2 O Filtro de Kalman Estendido - FKE

A maioria dos sistemas presentes na natureza são não-lineares, como comentado no capítulo 2, e o filtro de Kalman é um estimador para sistemas lineares, ou seja, como aplicar o FK em sistemas não-lineares, uma vez que este é um estimador ótimo de sistemas lineares. O FKE permite a aplicação do filtro de Kalman a sistemas não-lineares, tornando-se assim uma das mais aplicadas [Haykin 2001] derivações do FK aplicado a sistemas não lineares [Jazwinski 1970].

Além do EKF existe também o filtro de Kalman ‘unscented’ que é baseado na transformação ‘unscented’ apresentada por Julier et al. em [Julier, Uhlmann e Durrant-Whyte 2000]. Wan et al. apresenta uma aplicação do filtro de Kalman ‘unscented’ na estimação conjunta de estados e parâmetros em [Wan, Merwe e Nelson 2000][Haykin 2001, cap. 7].

Diversos autores investigaram o uso do filtro de Kalman estendido (FKE) na estimação de parâmetros de sistemas dinâmicos (lineares ou não-lineares). Esta idéia não é recente, como demonstra [Jazwinski 1970]. No caso da estimação apenas de parâmetros, o problema pode ser formulado ainda como o de estimação de estados de um sistema dinâmico estocástico, onde o filtro de Kalman possui a mesma formulação do algoritmo de quadrados mínimos recursivo com ganho normalizado [Ljung 1999]. Quando o problema envolve estimação simultânea de estados e de parâmetros de um processo, podendo servir de base para controle adaptativo ou mesmo para controle preditivo de forma adaptativa, uma reformulação aumentada do problema em espaço-de-estados é a solução mais comumente empregada [Chen e Liu 2000, Simon 2006].

Entretanto, o emprego deste estimador recursivo inspira cuidado, principalmente por empregar um modelo linearizado do problema de estimação simultânea dos estados do processo e dos parâmetros do modelo, o que pode resultar em divergência. Outros trabalhos empregaram a mesma idéia, como em [Leu e Baratti 2000] que apresenta uma abordagem sistemática de ajuste das matrizes de covariância do filtro.

O FKE foi utilizado por Williams em [Williams 1992] para ajustar os parâmetros de redes neurais recorrentes. Aragonés et al. em [Aragonés, Borges e Fournier 2002] utilizam o FKE como estimador de parâmetros do modelo cinemático de um robô móvel omnidirecional objetivando reduzir erros de odometria. Para problemas de estimação de estados de sistemas não-lineares a abordagem Bayesiana representada por Monte Carlo (filtro de Partículas) é outra solução sub-ótima que pode reduzir o risco de divergência como mostrado em [Doucet, Freitas e Gordon 2001].

Na sua derivação, algumas hipóteses são estabelecidas [Jazwinski 1970], tais como:

1. Incertezas da distribuição Gaussiana,
2. O conhecimento exato do modelo,
3. A consistência estatística da estimativa inicial.

Quando todas as hipóteses são respeitadas, a convergência e a consistência na estimação são garantidas. Para sistemas não-lineares discretos, este estimador tem sido aplicado utilizando o modelo linearizado do processo, que é obtido em torno da estimativa precedente (fase de predição) ou em torno da estimativa predita (fase de correção), quando as observações são integradas para

corrigir a estimativa predita de estado e sua matriz de covariâncias. Esta variante do estimador é conhecida como filtro de Kalman estendido (FKE). Entretanto, o FKE é um estimador sub-ótimo sem garantia de convergência [Jazwinski 1970].

Algumas técnicas de projeto e de ajuste têm sido usadas com o intuito de minimizar a possibilidade de divergência, fazendo do seu ajuste uma ‘arte’.

4.2.1 Algoritmo do Filtro de Kalman Estendido

O algoritmo do filtro de Kalman estendido é bem semelhante ao apresentado na secção 4.1.1. O que muda é que o modelo do processo agora utiliza as derivadas do modelo não-linear do sistema real, como mostra a 4.12. A fase de predição do filtro de Kalman estendido pode ser realizada utilizando o modelo não-linear 4.17, mas no passo de propagação das matrizes de covariâncias utilizam-se as matrizes Jacobianas do sistema não-linear como mostram as equações 4.13 e 4.18. Esta é a principal diferença em relação ao filtro de Kalman ‘unscented’, pois este não utiliza a Jacobiana na propagação de covariâncias.

Seja o seguinte sistema não-linear modelado no espaço-de-estados:

$$\begin{cases} \mathbf{x}_{k+1} &= f(k, \mathbf{x}_k) + \mathbf{w}_k \\ \mathbf{y}_k &= h(k, \mathbf{x}_k) + \mathbf{v}_k, \end{cases} \quad (4.12)$$

onde \mathbf{w}_k e \mathbf{v}_k são ruídos Gaussianos independentes de média nula e matrizes de covariâncias \mathbf{Q}_k e \mathbf{R}_k , respectivamente. Sejam as definições de \mathbf{F}_k e \mathbf{H}_k :

$$\begin{cases} \mathbf{F}_k &= \left. \frac{\partial f}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}_{k|k-1}, \mathbf{u}_k}, \\ \mathbf{H}_k &= \left. \frac{\partial h}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}_{k|k-1}}, \end{cases} \quad (4.13)$$

ou seja, \mathbf{F}_k e \mathbf{H}_k são as matrizes Jacobianas de $f(k, \mathbf{x}_k)$ e $h(k, \mathbf{x}_k)$

Inicialização:

$$k = 0, \quad (4.14)$$

$$\hat{\mathbf{x}}_0 = E[\mathbf{x}_0], \quad (4.15)$$

$$\mathbf{P}_0 = E[(\mathbf{x}_0 - E[\mathbf{x}_0])(\mathbf{x}_0 - E[\mathbf{x}_0])^T]. \quad (4.16)$$

Fase de predição da estimação:

$$\hat{\mathbf{x}}_{k|k-1} = f(k, \hat{\mathbf{x}}_{k-1|k-1}, \mathbf{u}_k, 0). \quad (4.17)$$

Propagação da matriz de covariância do erro de estimação:

$$\mathbf{P}_k^- = \mathbf{F}_{k|k-1} \mathbf{P}_{k-1} \mathbf{F}_{k|k-1}^T + \mathbf{Q}_{k-1}. \quad (4.18)$$

A matriz de ganho de Kalman é definida como:

$$\mathbf{K}_k = \mathbf{P}_k \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_k \mathbf{H}_k^T + \mathbf{R}_k). \quad (4.19)$$

Fase de correção do valor predito

$$\hat{\mathbf{x}}_k^+ = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{y}_k - \mathbf{H}_k \hat{\mathbf{x}}_k^-). \quad (4.20)$$

Atualização da matriz de covariância do erro de estimação

$$\mathbf{P}_k^+ = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k^-. \quad (4.21)$$

4.2.2 Aplicação ao processo de nível de líquidos

Freitas et al. em [Freitas, Borges e Bauchspiess 2004] investigaram a aplicação de um filtro de Kalman estendido para a estimação on-line dos parâmetros de processos não-lineares reais de um sistema de nível de líquidos de terceira ordem, o mesmo sistema havia sido controlado via linearização exata por Gosmann em [Gosmann 2002]. Em simulações é sabido que não há maiores dificuldades, como também verificado neste trabalho, uma vez que não haja discrepância entre o modelo gerador dos sinais e o modelo utilizado pelo filtro de Kalman estendido. Neste trabalho apresenta-se o FKE como estimador de estados e parâmetros de um sistema de nível de líquidos de quarta ordem.

Como sempre existem discrepâncias entre o modelo utilizado no filtro de Kalman e o processo real é muito provável que haja dificuldades na implementação prática de um controlador baseado nos parâmetros estimados pelo filtro de Kalman. Seja $\mathbf{x} = [h_1 \ h_2 \ h_3 \ h_4]^T$ e $\theta = [k_2 \ k_4 \ k_{12} \ k_{23} \ k_{34}]^T$ vetores representando as variáveis de estado e os parâmetros de interesse do modelo apresentado no Capítulo 3. A estimação recursiva e simultânea destas variáveis é feita considerando-se o seguinte modelo estendido para a evolução em tempo discreto dos estados:

$$\mathbf{z}_k = \begin{bmatrix} \mathbf{x}_k \\ \theta_k \end{bmatrix} + \mathbf{w}_k = \begin{bmatrix} h_1 \\ h_2 \\ h_3 \\ h_4 \\ k_2 \\ k_4 \\ k_{12} \\ k_{23} \\ k_{34} \end{bmatrix} + \mathbf{w}_k, \quad (4.22)$$

no qual \mathbf{z}_k é o vetor de estados estendido, estados e parâmetros do sistema, $\mathbf{w}_k \sim N(0, \mathbf{Q}_k)$ é um ruído Gaussiano branco e k é o índice de tempo discreto. O processo \mathbf{w}_k modela as incertezas na evolução de \mathbf{x} e de θ , que incluem imperfeições do modelo. Entretanto, supor que \mathbf{w}_k é Gaussiano pode ser uma aproximação grosseira, principalmente quando se lida com modelos não-lineares. Uma apropriada escolha de sua matriz de covariâncias \mathbf{Q}_k de modo que suas componentes modelem uma

incerteza superior às incertezas intrínsecas do processo pode minimizar o risco de divergência da estimação [Jazwinski 1970].

Devido à dificuldade em determinar correlações entre as incertezas da evolução de \mathbf{x} e de θ , \mathbf{Q}_k é suposta uma matriz diagonal, com os elementos da diagonal principal representando as variâncias dos ruídos gaussianos de evolução de cada variável de estado do modelo estendido, logo temos:

$$\mathbf{Q}_k = \begin{bmatrix} 0,05 \cdot I_{4 \times 4} & \mathbf{0}_{5 \times 5} \\ \mathbf{0}_{4 \times 4} & 0,01 \cdot I_{5 \times 5} \end{bmatrix}, \quad (4.23)$$

note que mesmo \mathbf{Q}_k podendo variar em função do índice de tempo discreto, mas neste trabalho utiliza-se um valor constante.

De acordo com o formalismo do FKE, com a evolução no tempo do processo, são mantidas estimativas de $\hat{\mathbf{z}}_k$ e de sua matriz de covariâncias $\hat{\mathbf{P}}_k$. Por meio da predição, $\hat{\mathbf{z}}_{k-1}$ e $\hat{\mathbf{P}}_{k-1}$ são propagadas ao instante k , resultando assim em $\hat{\mathbf{z}}_{k|k-1}$ e $\hat{\mathbf{P}}_{k|k-1}$, como mostrado na sub-seção 4.2.1.

Quando observações são efetuadas sobre o processo físico, estas são usadas para corrigir as estimativas preditas. Para tanto, o seguinte modelo de medição é usado:

$$\mathbf{y}_k = \begin{bmatrix} I_{4 \times 4} & \mathbf{0}_{4 \times 5} \\ \mathbf{0}_{5 \times 4} & \mathbf{0}_{5 \times 5} \end{bmatrix} \mathbf{z}_k + \mathbf{v}_k, \quad (4.24)$$

no qual $\mathbf{v}_k \approx N(0, \mathbf{R}_k)$ é um ruído branco de medição, suposto Gaussiano. A integração das medições é feita usando as fórmulas de atualização do FKE, veja 4.2.1, resultando assim em estimativas $\hat{\mathbf{z}}_k$ e $\hat{\mathbf{P}}_k$. Note que a medição ocorre somente nas variáveis de estado do sistema, pois não existe sensor para medir os parâmetros do processo. Considerando o novo modelo estendido de estados e parâmetros, 4.22, temos as seguintes matrizes como Jacobianas do novo sistema

$$J_{fk} = \begin{bmatrix} 0 & \frac{-\text{signal}(h_1-h_2)\sqrt{|h_1-h_2|}}{A} & 0 & 0 & 0 \\ \frac{\sqrt{h_2}}{A} & \frac{\text{signal}(h_1-h_2)\sqrt{|h_1-h_2|}}{A} & \frac{-\text{signal}(h_2-h_3)\sqrt{|h_2-h_3|}}{A} & 0 & 0 \\ 0 & 0 & \frac{\text{signal}(h_2-h_3)\sqrt{|h_2-h_3|}}{A} & \frac{-\sqrt{h_3-h_4}}{A} & 0 \\ 0 & 0 & 0 & \frac{\sqrt{h_3-h_4}}{A} & \frac{-\sqrt{h_4}}{A_4} \end{bmatrix}, \quad (4.25)$$

$$J_{fx} = \frac{1}{2A} \begin{bmatrix} \frac{\partial f_1}{\partial h_1} & \frac{\partial f_1}{\partial h_2} & \frac{\partial f_1}{\partial h_3} & \frac{\partial f_1}{\partial h_4} \\ \frac{\partial f_2}{\partial h_1} & \frac{\partial f_2}{\partial h_2} & \frac{\partial f_2}{\partial h_3} & \frac{\partial f_2}{\partial h_4} \\ \frac{\partial f_3}{\partial h_1} & \frac{\partial f_3}{\partial h_2} & \frac{\partial f_3}{\partial h_3} & \frac{\partial f_3}{\partial h_4} \\ \frac{\partial f_4}{\partial h_1} & \frac{\partial f_4}{\partial h_2} & \frac{\partial f_4}{\partial h_3} & \frac{\partial f_4}{\partial h_4} \end{bmatrix},$$

onde:

$$\frac{\partial f_1}{\partial h_1} = -\frac{k_{12}\text{signal}(h_1 - h_2)}{\sqrt{|h_1 - h_2|}}, \quad (4.27)$$

$$\frac{\partial f_1}{\partial h_2} = -\frac{k_{12}\text{signal}(h_1 - h_2)}{\sqrt{|h_1 - h_2|}}, \quad (4.28)$$

$$\frac{\partial f_1}{\partial h_3} = 0, \quad (4.29)$$

$$\frac{\partial f_1}{\partial h_4} = 0, \quad (4.30)$$

$$\frac{\partial f_2}{\partial h_1} = \frac{k_{12}\text{signal}(h_1 - h_2)}{\sqrt{|h_1 - h_2|}}, \quad (4.31)$$

$$\frac{\partial f_2}{\partial h_2} = -\frac{k_{23}\text{signal}(h_2 - h_3)}{\sqrt{|h_2 - h_3|}} + \frac{k_{12}\text{signal}(h_1 - h_2)}{\sqrt{|h_1 - h_2|}} - \frac{k_2}{\sqrt{h_2}}, \quad (4.32)$$

$$\frac{\partial f_2}{\partial h_3} = -\frac{k_{23}\text{signal}(h_2 - h_3)}{\sqrt{|h_2 - h_3|}}, \quad (4.33)$$

$$\frac{\partial f_2}{\partial h_4} = 0, \quad (4.34)$$

$$\frac{\partial f_3}{\partial h_1} = 0, \quad (4.35)$$

$$\frac{\partial f_3}{\partial h_2} = \frac{k_{23}\text{signal}(h_2 - h_3)}{\sqrt{|h_2 - h_3|}}, \quad (4.36)$$

$$\frac{\partial f_3}{\partial h_3} = -\frac{k_{34}\text{signal}(h_3 - h_4)}{\sqrt{|h_3 - h_4|}} + \frac{k_{23}\text{signal}(h_2 - h_3)}{\sqrt{|h_2 - h_3|}}, \quad (4.37)$$

$$\frac{\partial f_3}{\partial h_4} = -\frac{k_{34}\text{signal}(h_3 - h_4)}{\sqrt{|h_3 - h_4|}}, \quad (4.38)$$

$$\frac{\partial f_4}{\partial h_1} = 0, \quad (4.39)$$

$$\frac{\partial f_4}{\partial h_2} = 0, \quad (4.40)$$

$$\frac{\partial f_4}{\partial h_3} = \frac{k_{34}\text{signal}(h_3 - h_4)}{\sqrt{|h_3 - h_4|}}, \quad (4.41)$$

$$\frac{\partial f_4}{\partial h_4} = -\frac{k_{34}\text{signal}(h_3 - h_4)}{\sqrt{|h_3 - h_4|}} - \frac{k_4}{\sqrt{h_4}}, \quad (4.42)$$

$$, \quad (4.43)$$

assim o modelo linearizado \mathbf{F} utilizado na propagação das covariâncias do filtro de Kalman estendido aplicado ao sistema de nível de líquidos é:

$$\mathbf{F}_{9 \times 9} = \begin{bmatrix} J_{fx} & J_{fk} \\ 0_{5 \times 4} & I_{5 \times 5} \end{bmatrix},$$

Nota-se que o modelo de medição incorpora simultaneamente medições de nível dos quatro tanques. Estas medições são supostas independentes, o que é razoável dado o processo em questão, resultando em R_k uma matriz diagonal. E mais, sendo as medições variáveis do modelo que são os níveis de cada tanque, fica mais fácil controlar a convergência de suas estimativas dadas pelas quatro primeiras componentes de \hat{z}_k . De fato, estas estimativas podem divergir apenas

se as componentes associadas ao ruído de processo \mathbf{w}_k forem consideradas de variância muito pequena com relação ao ruído de medição \mathbf{v}_k . Isto torna mais fácil determinar as quatro primeiras componentes \mathbf{Q}_k . \mathbf{R}_k é relacionada à precisão e repetibilidade do sensor de nível, e pode ser determinada experimentalmente.

Por outro lado, determinar as componentes de \mathbf{Q}_k associadas aos parâmetros θ_k não é uma tarefa fácil. Com um sistema real isto é ainda dificultado pelo fato do filtro empregar um modelo de processo, equação (4.13), aproximado para propagação das covariâncias. Neste caso, a convergência de \mathbf{x}_k pode levar à divergência de θ_k , uma vez que erros de modelagem, modelo apresentado na equação 4.22, são propagados pelas correlações cruzadas estabelecidas pelo modelo.

4.3 Conclusões

Este capítulo apresentou um resumo sobre o filtro de Kalman e sua principal derivação para sistemas não-lineares, o filtro de Kalman estendido. Além disso apresentou-se também a derivação do FKE na estimação conjunta de estados e parâmetros do sistema de nível de líquidos com todas as equações e parâmetros do processo. Os algoritmos básicos tanto do filtro de Kalman quanto do FKE foram mostrados de forma resumida, bem como as referências e outros trabalhos apresentados.

A aplicação do FKE como estimador de parâmetros do sistema de nível de líquidos foi apresentada em detalhe para um sistema tanques acoplados de quarta ordem.

Capítulo 5

Linearização Exata Adaptativa

Este capítulo apresenta a proposta de controle utilizada neste trabalho para sistemas não-lineares. A LEA consiste no uso de um estimador sub-ótimo, o filtro de Kalman estendido, que realiza a estimação conjunta de estados e parâmetros do processo melhorando o controle não-linear por linearização exata. Assim tem-se um modelo linear para uso no controle preditivo baseado em modelo. Este modelo dinâmico simplificado não sofre influência dos parâmetros do processo.

Introdução

A linearização de sistemas não-lineares em torno de um ponto de operação e um controlador linear é uma das formas de atuação mais usuais. Esse método tem como principal vantagem possibilitar a aplicação das técnicas de síntese de controladores lineares, esta mais consagrada que a teoria de sistemas não-lineares. A desvantagem é que essa aproximação é válida apenas numa região em torno do ponto de operação do sistema.

A linearização exata por realimentação é a solução para eliminação da dependência do ponto de operação. Esse método transforma o sistemas não-linear em duas malhas de controle, uma malha externa dinâmica e linear na forma canônica de Brunovsky e uma malha interna estática e não-linear, como mostra Figura 5.1. Essa transformação, uma cópia difeomórfica do sistema, ocorre na forma de mudança de variáveis de estado e de sinal de controle do sistema, assim há um sistema linear onde o conjunto de variáveis de estado é diferente do conjunto do sistema não-linear original. Neste contexto, as técnicas de sistemas lineares podem ser aplicadas facilmente na malha dinâmica e linear gerada pela linearização exata, esta malha é composta pela associação entre a malha interna não-linear e o sistema não-linear. Desta forma, ocorre um cancelamento das não-linearidades do sistema com as suas inversas na linearização exata e gera-se um modelo na forma de cadeia de integradores que poderá ser controlado utilizando-se técnicas lineares [Isidori 1989].

A linearização exata é um boa técnica para controle de sistemas não-lineares, mas esta não é aplicável a qualquer sistema, mas somente a sistemas onde seja possível encontrar uma trans-

formação difeomórfica que gere um sistema linear na forma canônica de Brunovsky. Ou seja, para um conjunto de variáveis de estado $\{x_1, x_2, x_3, \dots, x_n\}$, e uma transformação de variáveis $z = \Theta = \{z_1, z_2, z_3, \dots, z_n\}$, onde as funções de coordenadas de Θ forem continuamente diferenciáveis em relação às variáveis $\{x_1, x_2, x_3, \dots, x_n\}$ e se, além disso, essa transformação for bijetora. Resumidamente, para que a aplicação da linearização exata a sistema não-linear seja possível é necessário a existência de uma transformação de variáveis bijetora e continuamente diferenciável.

Utilizando o método da linearização entrada-saída tem-se que para que um sistema não-linear seja completamente linearizável é necessário que este tenha grau relativo igual ao número de estados. Ou seja, seja r_i um dos graus relativos do sistema multivariável, para este seja linearizável é necessário:

$$\sum r_i = n, \quad (5.1)$$

onde n é o número de estados do sistema. Quando $\sum r_i < n$ tem-se dois sub-sistemas um linearizável e outro denominado dinâmica nula. Devasia et al. em [Devasia, Chen e Paden 1996] apresentam um método para eliminação da dinâmica nula de um sistema pela adição de um sinal de atuação ao sinal gerado após a linearização exata.

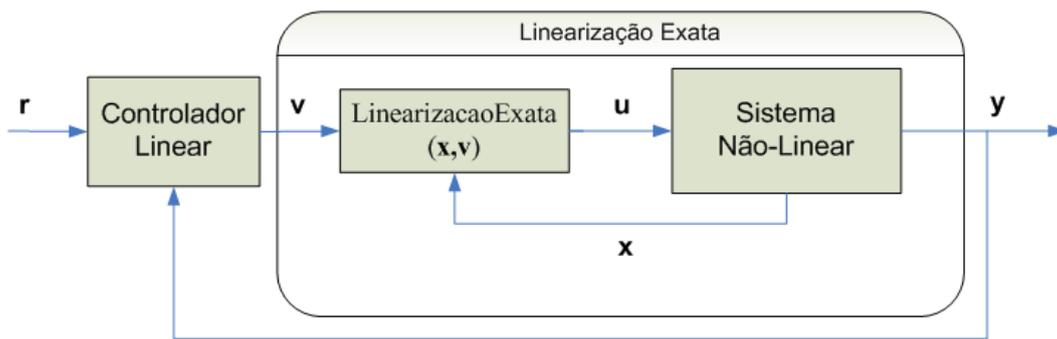


Figura 5.1: Estrutura do Controle por Linearização Exata

5.1 Linearização Exata Adaptativa

A proposta de controle não-linear deste trabalho é baseado no uso de técnicas lineares aplicadas a sistemas não-lineares. O modelo resultante da aplicação da linearização exata adaptativa a um sistema não-linear é linear e desacoplado. O modelo resultante pode ser controlado com qualquer técnica de controle linear como PID, alocação de pólos, controle ótimo, controle preditivo baseado em modelo, controle robusto linear dentre outras técnicas lineares.

Um das grandes desvantagens da linearização exata é a dependência dos valores do conjunto de parâmetros do modelo não-linear conforme apresentado em [Sousa 1998, Isidori 1989, Franco 2006]. Afim de contornar tal problema a linearização exata neste trabalho será associada ao filtro de Kalman de estendido, apresentado no Capítulo 4 utilizado como estimador de estados e parâmetros de forma conjunta. Assim tem-se a linearização exata adaptativa que fornece um

modelo linear para o controlador preditivo baseado em modelo. A adaptação ocorre somente na parte estática e não-linear, ver $LinearizacaoExata(\mathbf{x}, \theta, \mathbf{v})$ na Figura 5.1, assim o modelo dinâmico permanece o mesmo durante toda a execução do processo. Isso facilita a aplicação do controlador e melhora o resultado do sistema como um todo, assim pode-se, por exemplo, aplicar um controle ótimo ao sistema linear que este será válido em toda a faixa de operação do sistema não-linear. A Figura 5.1 apresenta a estrutura na forma de diagrama de blocos da linearização exata adaptativa.

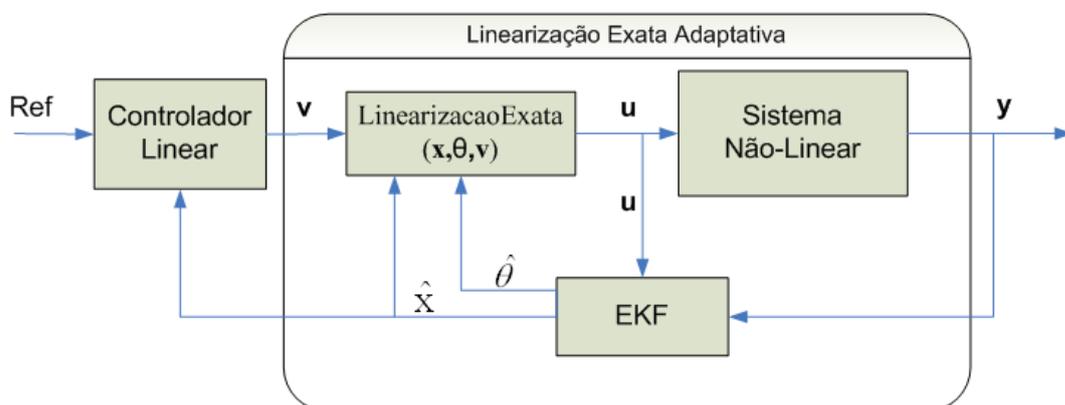


Figura 5.2: Estrutura da Linearização Exata Adaptativa

5.2 Linearização Exata

A eliminação da dependência do ponto de operação e a possibilidade do uso de técnicas lineares de controle de processos são os objetivos alcançados com a linearização exata de um processo. Em Foss et al [Foss, Johansen e Sorenson 1994] apresenta-se uma aplicação de controle preditivo utilizando modelos locais, como os modelos apresentados na seção anterior, ou seja uma configuração sub-ótima que é o controle preditivo aplicado a um modelo sub-ótimo de linearização local do processo. Com a linearização exata elimina-se a adaptação no controle que se faz necessário quando se utilizam técnicas como EKF em [Freitas, Borges e Bauchspiess 2004], filtros de partículas [Liu e Chen 1998] e outras técnicas sub-ótimas para estimação de sistemas [Ljung 1999, Hangos, Bokor e Szederkényi 2004].

Diversos sistemas não-lineares, assim como o sistema de nível de líquidos do LAVSI, podem ser descritos como:¹

¹Nesta seção h_i é uma função não-linear que mapea os estados para uma saída do sistema e não mais representa um nível de líquido.

$$\begin{cases} \frac{d\mathbf{x}}{dt} = f(\mathbf{x}) + \sum_i^{m+} g_i(\mathbf{x})u_i \\ y_1 = h_1(\mathbf{x}) \\ y_2 = h_2(\mathbf{x}) \\ \dots \\ y_m = h_m(\mathbf{x}) \end{cases} \quad (5.2)$$

onde h_i não representa o nível de um tanque mas uma função não-linear entre os estados do sistema e uma das saída deste.

O sistema possuirá grau relativo r se para todo 1 menor ou igual a j que seja menor ou igual a m , para todo 1 menor ou igual a i que é menor ou igual a m para todo $k < r_i - 1$, e para todo x em uma vizinhança de x_0 e a matriz A (5.3) tiver posto pleno.

$$A(x) = \begin{bmatrix} L_{g_i} L_f^k h_i(x) = 0 \\ L_{g_1} L_f^{r_1-1} h_1(x) & L_{g_2} L_f^{r_1-1} h_1(x) & \dots & L_{g_m} L_f^{r_1-1} h_1(x) \\ L_{g_1} L_f^{r_2-1} h_2(x) & \dots & \dots & L_1 h_2(x) \\ \vdots & \vdots & \vdots & \vdots \\ L_{g_1} L_f^{r_m-1} h_m(x) & \dots & \dots & L_{g_m} L_f^{r_m-1} h_m(x) \end{bmatrix} \quad (5.3)$$

As funções $L_{g_i} L_f^k h_i(x)$ são definidas recursivamente como

$$L_{g_i} L_f^k h_i(\mathbf{x}) = \frac{\partial L_{g_i} L_f^{k-1} h_i(\mathbf{x})}{\partial \mathbf{x}} f(\mathbf{x}), \quad (5.4)$$

com $L_f^0 h_i(\mathbf{x}) = h_i(\mathbf{x})$. A função $L_f h_i(x)$ é chamada de derivada de h_i ao longo de f (derivada de Lie) e é definida como:

$$L_f h(\mathbf{x}) = \sum_{i=1}^n \frac{\partial h_i(\mathbf{x})}{\partial \mathbf{x}} f_i(\mathbf{x}), \quad (5.5)$$

da mesma forma, a derivada de h_i ao longo de f e depois ao longo de g é dada por:

$$L_g L_f h_i(\mathbf{x}) = \frac{\partial L_f h_i(\mathbf{x})}{\partial \mathbf{x}} g(\mathbf{x}). \quad (5.6)$$

Fazendo uma substituição do sinal de atuação do sistema não-linear tem-se o seguinte modelo:

$$\begin{aligned}
\frac{d\mathbf{x}}{dt} &= f(\mathbf{x}) + g(\mathbf{x})\rho_a(\mathbf{x}) + g(\mathbf{x})\rho_b(\mathbf{x}) \\
y_1 &= h_1(\mathbf{x}) \\
y_2 &= h_2(\mathbf{x}) \\
&\dots \\
y_m &= h_m(\mathbf{x})
\end{aligned} \tag{5.7}$$

$$\begin{aligned}
\rho_a(\mathbf{x}) &= -A(\mathbf{x})B(\mathbf{x}) \\
\rho_b(\mathbf{x}) &= A^{-1}(\mathbf{x}),
\end{aligned} \tag{5.8}$$

onde A está definida em 5.3 e B é definida como

$$B(\mathbf{x}) = \begin{bmatrix} L_f^{r_1-1} h_1(\mathbf{x}) \\ \vdots \\ \vdots \\ L_f^{r_m} h_m(\mathbf{x}) \end{bmatrix}, \tag{5.9}$$

nesse caso o conjunto de funções

$$\phi_k^i(\mathbf{x}) = L_f^{k-1} h_i(\mathbf{x}) \tag{5.10}$$

para todo $1 \leq k \leq r_i$ e $1 \leq i \leq m$ definem uma transformação de coordenadas em x^0 que, juntamente com a realimentação de estados

$$\mathbf{u} = \rho_a + \rho_b \mathbf{v}, \tag{5.11}$$

levam o sistema para uma representação linear e controlável.

Note que o sinal de atuação do sistema será resultado da aplicação de uma função não-linear estática que depende tanto dos estados como dos parâmetros do sistema não-linear, de fato, como ocorrerá um cancelamento de não-linearidades este será efetivo quando o modelo e os parâmetros do modelo estiverem coerentes e próximos dos valores reais. A inclusão de estimação sub-ótima de sistemas não-lineares tem como objetivo tornar os parâmetros e estados mais próximos dos valores reais gerando assim um cancelamento de não-linearidades válido em toda a faixa de operação.

5.3 Linearização Exata do Sistema de Nível de 4ª Ordem

A linearização do processo de quarta ordem de tanque acoplados, ver Capítulo 3, gera um modelo linear desacoplado, ou seja, obtêm-se dois sub-sistemas de segunda ordem na forma de cadeia de integradores, como mostrado na Figura 5.3

, onde v_1 e v_2 são as saídas variáveis manipuladas pelo controlador linear, utilizadas para diferenciar do sinal de controle, u , aplicado no sistema não-linear.

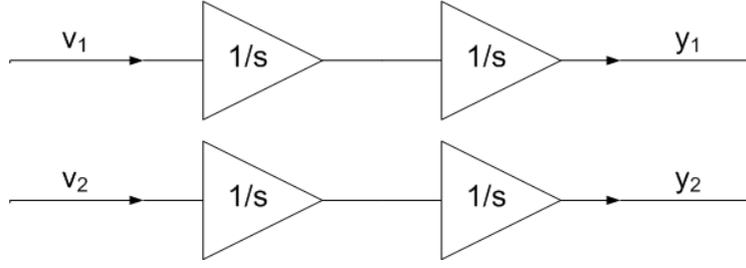


Figura 5.3: Sistema linear obtido com a linearização exata do sistemas de nível de líquidos

Utilizando o modelo da equação 3.4 e definindo as alturas dos níveis h_2 e h_4 como as variáveis controladas, tem-se uma configuração multivariável do sistema de nível de líquidos pode-se aplicar as técnicas de linearização exata de sistemas não-lineares. Seguindo o formalismo da linearização exata apresentado em [Sousa 1998, Isidori 1989] e adotando-se a notação $x_i = h_i$, para $1 \leq i \leq 4$ tem-se o seguinte resultado:

$$\dot{\mathbf{x}} = f(\mathbf{x}) + g_1(\mathbf{x})u_1 + g_2(\mathbf{x})u_2, \quad (5.12)$$

com

$$y_1 = h_1(\mathbf{x}) = x_2, \quad (5.13)$$

$$y_2 = h_2(\mathbf{x}) = x_4, \quad (5.14)$$

$$(5.15)$$

sendo estas, no caso do sistema de nível:

$$\mathbf{f}(\mathbf{x}) = \begin{bmatrix} f_1(\mathbf{x}) \\ f_2(\mathbf{x}) \\ f_3(\mathbf{x}) \\ f_4(\mathbf{x}) \end{bmatrix}, \quad g_1(\mathbf{x}) = \begin{bmatrix} \frac{1}{A} \\ 0 \\ 0 \\ 0 \end{bmatrix}, \quad g_2(\mathbf{x}) = \begin{bmatrix} 0 \\ 0 \\ \frac{1}{A} \\ 0 \end{bmatrix}, \quad (5.16)$$

onde, fazendo $A_1 = A_2 = A_3 = A$ na equação 3.12 tem-se:

$$f_1(\mathbf{x}) = \frac{1}{A}(-k_{12}\text{signal}(x_1 - x_2)\sqrt{|x_1 - x_2|}) \quad (5.17)$$

$$f_2(\mathbf{x}) = \frac{1}{A}(k_{12}\text{signal}(x_1 - x_2)\sqrt{|x_1 - x_2|} - k_{23}\text{signal}(x_2 - x_3)\sqrt{|x_2 - x_3|} - k_{o2}\sqrt{x_2}) \quad (5.18)$$

$$f_3(\mathbf{x}) = \frac{1}{A}(k_{23}\text{signal}(x_2 - x_3)\sqrt{|x_2 - x_3|} - k_{34}\text{signal}(x_3 - x_4)\sqrt{|x_3 - x_4|}) \quad (5.19)$$

$$f_4(\mathbf{x}) = \frac{1}{A_4}(k_{34}\text{signal}(x_3 - x_4)\sqrt{|x_3 - x_4|} - k_{o4}\sqrt{x_4}), \quad (5.20)$$

Deve-se calcular $L_f^k h_i(x)$:

Para $i = 1$ tem-se:

$$L_f^0 h_1(\mathbf{x}) = h_1(\mathbf{x}) = x_2 \quad (5.21)$$

$$L_f^1 h_1(\mathbf{x}) = \frac{\partial h_1}{\partial x} f(\mathbf{x}) = \begin{bmatrix} 0 & 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} f_1(\mathbf{x}) \\ f_2(\mathbf{x}) \\ f_3(\mathbf{x}) \\ f_4(\mathbf{x}) \end{bmatrix} = f_2(\mathbf{x}) \quad (5.22)$$

$$L_f^2 h_1(\mathbf{x}) = \frac{\partial f_2}{\partial x} f(\mathbf{x}) = \frac{\partial f_2}{\partial x} \begin{bmatrix} f_1(\mathbf{x}) \\ f_2(\mathbf{x}) \\ f_3(\mathbf{x}) \\ f_4(\mathbf{x}) \end{bmatrix}, \quad (5.23)$$

onde:

$$\frac{\partial f_2}{\partial x} = \frac{1}{2A} \begin{bmatrix} \frac{k_{12} \text{signal}(h_1-h_2)}{\sqrt{|h_1-h_2|}} & \frac{k_{12} \text{signal}(h_1-h_2)}{\sqrt{|h_1-h_2|}} - \frac{k_{23} \text{signal}(h_2-h_3)}{\sqrt{|h_2-h_3|}} - \frac{k_2}{\sqrt{h_2}} & -\frac{k_{23} \text{signal}(h_2-h_3)}{\sqrt{|h_2-h_3|}} & 0 \end{bmatrix} \quad (5.24)$$

Para $i = 2$ tem-se que:

$$L_f^0 h_2(\mathbf{x}) = h_2(\mathbf{x}) = x_4 \quad (5.25)$$

$$L_f^1 h_2(\mathbf{x}) = \frac{\partial h_2}{\partial x} f(\mathbf{x}) = \begin{bmatrix} 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} f_1(\mathbf{x}) \\ f_2(\mathbf{x}) \\ f_3(\mathbf{x}) \\ f_4(\mathbf{x}) \end{bmatrix} = f_4(\mathbf{x}) \quad (5.26)$$

$$\begin{aligned} L_f^2 h_2(\mathbf{x}) &= \frac{\partial f_4}{\partial x} f(\mathbf{x}) \\ &= \frac{1}{2A} \begin{bmatrix} 0 & 0 & \frac{k_{34} \cdot \text{signal}(x_3-x_4)}{\sqrt{|x_3-x_4|}} & \left(-\frac{k_{34} \cdot \text{signal}(x_3-x_4)}{\sqrt{|x_3-x_4|}} - \frac{k_4}{\sqrt{x_4}}\right) \end{bmatrix} \begin{bmatrix} f_1(\mathbf{x}) \\ f_2(\mathbf{x}) \\ f_3(\mathbf{x}) \\ f_4(\mathbf{x}) \end{bmatrix}, \end{aligned} \quad (5.27)$$

tem-se ainda que a derivada Lie para o sistema de nível de líquidos de h_i ao longo de f e depois ao longo de g é:

$$L_{g_1} L_f^0 h_1(\mathbf{x}) = \frac{\partial h_1}{\partial x} g_1(\mathbf{x}) = \begin{bmatrix} 0 & 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} 1/A \\ 0 \\ 0 \\ 0 \end{bmatrix} = 0, \quad (5.28)$$

$$L_{g_1} L_f^1 h_1(\mathbf{x}) = \frac{\partial f_2}{\partial x} g_1(\mathbf{x}) = \begin{bmatrix} \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} & \frac{\partial f_2}{\partial x_3} & \frac{\partial f_2}{\partial x_4} \end{bmatrix} \begin{bmatrix} 1/A \\ 0 \\ 0 \\ 0 \end{bmatrix} \neq 0, \quad (5.29)$$

$$= \frac{1}{A} \frac{\partial f_2}{\partial x_1} \neq 0, \quad (5.30)$$

$$= \frac{1}{2A^2} \frac{k_{12} \cdot \text{signal}(x_1 - x_2)}{\sqrt{|x_1 - x_2|}} \neq 0, \quad (5.31)$$

como o resultado é não nulo deve-se parar o procedimento e iniciar o mesmo procedimento da derivada Lie em ao longo de g_2 ,

$$L_{g_2}L_f^0h_1(\mathbf{x}) = \frac{\partial h_1}{\partial \mathbf{x}}g_2(\mathbf{x}) = \begin{bmatrix} 0 & 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ 1/A \\ 0 \end{bmatrix} = 0 \quad (5.32)$$

$$L_{g_2}L_f^1h_1(\mathbf{x}) = \frac{\partial f_2}{\partial \mathbf{x}}g_2(\mathbf{x}) = \begin{bmatrix} \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} & \frac{\partial f_2}{\partial x_3} & \frac{\partial f_2}{\partial x_4} \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ 1/A \\ 0 \end{bmatrix} \neq 0 \quad (5.33)$$

$$= \frac{1}{A} \frac{\partial f_2}{\partial x_3} \neq 0, \quad (5.34)$$

logo conclui-se que $r_1 = 2$. Assim caso r_2 seja igual a 2 teremos o sistema com grau relativo completo e linearizável, procede-se então com o cálculo de r_2

$$L_{g_2}L_f^1h_1(\mathbf{x}) = \frac{1}{2A^2} \frac{k_{23} \cdot \text{signal}(x_2 - x_3)}{\sqrt{|x_2 - x_3|}} \quad (5.35)$$

como o resultado é não nulo tem-se que $r_1 = 2$. Da mesma forma:

$$L_{g_1}L_f^0h_2(\mathbf{x}) = \frac{\partial h_2}{\partial \mathbf{x}}g_1 = \begin{bmatrix} 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1/A \\ 0 \\ 0 \\ 0 \end{bmatrix} = 0 \quad (5.36)$$

$$L_{g_1}L_f^1h_2(\mathbf{x}) = \frac{\partial f_4}{\partial \mathbf{x}}g_1 = \begin{bmatrix} \frac{\partial f_4}{\partial x_1} & \frac{\partial f_4}{\partial x_2} & \frac{\partial f_4}{\partial x_3} & \frac{\partial f_4}{\partial x_4} \end{bmatrix} \begin{bmatrix} 1/A \\ 0 \\ 0 \\ 0 \end{bmatrix} = 0, \quad (5.37)$$

logo para g_2 tem-se:

$$L_{g_2}L_f^1h_2(\mathbf{x}) = \frac{\partial f_4}{\partial \mathbf{x}}g_2 = \begin{bmatrix} \frac{\partial f_4}{\partial x_1} & \frac{\partial f_4}{\partial x_2} & \frac{\partial f_4}{\partial x_3} & \frac{\partial f_4}{\partial x_4} \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ 1/A \\ 0 \end{bmatrix} = \frac{1}{2A^2} \frac{k_{34} \cdot \text{signal}(x_3 - x_4)}{\sqrt{|x_3 - x_4|}}, \quad (5.38)$$

ou seja, tem-se que $r_2 = 2$ logo como o grau relativo do sistema está completo este não possui dinâmica nula para as saídas selecionadas. Assim tem-se as matrizes A e B da equação 5.9 como:

$$A = \begin{bmatrix} L_{g_1}L_f^1h_1(\mathbf{x}) & L_{g_2}L_f^1h_1(\mathbf{x}) \\ L_{g_1}L_f^1h_2(\mathbf{x}) & L_{g_2}L_f^1h_2(\mathbf{x}) \end{bmatrix}, \quad (5.39)$$

substituindo os valores encontrados na equação 5.39 tem-se que:

$$A = \begin{bmatrix} \frac{1}{2A^2} \frac{k_{12} \cdot \text{signal}(x_1 - x_2)}{\sqrt{|x_1 - x_2|}} & \frac{1}{2A^2} \frac{k_{23} \cdot \text{signal}(x_2 - x_3)}{\sqrt{|x_2 - x_3|}} \\ 0 & \frac{1}{2A^2} \frac{k_{34} \cdot \text{signal}(x_3 - x_4)}{\sqrt{|x_3 - x_4|}} \end{bmatrix}, \quad (5.40)$$

nota-se que A tem posto pleno, ou seja, $\text{posto}(A(x)) = 2$.

Assim tem-se que o sistema possui grau relativo $r_1, r_2 = 2, 2$ em qualquer ponto x^0 , desde que que $x_1 \neq x_2$, $x_2 \neq x_3$ e $x_3 \neq x_4$. Se x^0 é tal que $x_1 = x_2$ ou $x_2 = x_3$ ou $x_3 = x_4$ nenhum grau relativo pode ser definido.

Sabe-se que:

$$B = \begin{bmatrix} L_f^2 h_1(x) \\ L_f^2 h_2(x) \end{bmatrix}, \quad (5.41)$$

onde:

$$L_f^2 h_1(x) = \frac{\partial f_2}{\partial x} f(x) = \begin{bmatrix} \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} & \frac{\partial f_2}{\partial x_3} & \frac{\partial f_2}{\partial x_4} \end{bmatrix} \begin{bmatrix} f_1(x) \\ f_2(x) \\ f_3(x) \\ f_4(x) \end{bmatrix} \quad (5.42)$$

e

$$L_f^2 h_2(x) = \frac{\partial f_4}{\partial x} f(x) = \begin{bmatrix} \frac{\partial f_4}{\partial x_1} & \frac{\partial f_4}{\partial x_2} & \frac{\partial f_4}{\partial x_3} & \frac{\partial f_4}{\partial x_4} \end{bmatrix} \begin{bmatrix} f_1(x) \\ f_2(x) \\ f_3(x) \\ f_4(x) \end{bmatrix} \quad (5.43)$$

os valores da derivadas parciais foram apresentados no Capítulo 4 na seção 4.2.2 e os valores da funções $f_1(\mathbf{x})$, $f_2(\mathbf{x})$, $f_3(\mathbf{x})$, $f_4(\mathbf{x})$ estão nas equações 5.17 a 5.20. As derivadas parciais de interesse são:

$$\frac{\partial f_2}{\partial x_1} = \frac{1}{2A} \frac{k_{12} \text{signal}(x_1 - x_2)}{\sqrt{|x_1 - x_2|}} \quad (5.44)$$

$$\frac{\partial f_2}{\partial x_2} = -\frac{1}{2A} \frac{k_{23} \text{signal}(x_2 - x_3)}{\sqrt{|x_2 - x_3|}} + \frac{1}{2A} \frac{k_{12} \text{signal}(x_1 - x_2)}{\sqrt{|x_1 - x_2|}} - \frac{1}{2A} \frac{k_2}{\sqrt{x_2}} \quad (5.45)$$

$$\frac{\partial f_2}{\partial x_3} = -\frac{1}{2A} \frac{k_{23} \text{signal}(x_2 - x_3)}{\sqrt{|x_2 - x_3|}} \quad (5.46)$$

$$\frac{\partial f_2}{\partial x_4} = 0 \quad (5.47)$$

$$\frac{\partial f_4}{\partial x_1} = 0 \quad (5.48)$$

$$\frac{\partial f_4}{\partial x_2} = 0 \quad (5.49)$$

$$\frac{\partial f_4}{\partial x_3} = \frac{1}{2A} \frac{k_{34} \text{signal}(x_3 - x_4)}{\sqrt{|x_3 - x_4|}} \quad (5.50)$$

$$\frac{\partial f_4}{\partial x_4} = -\frac{1}{2A} \frac{k_{34} \text{signal}(x_3 - x_4)}{\sqrt{|x_3 - x_4|}} - \frac{1}{2A_4} \frac{k_4}{\sqrt{h_4}}. \quad (5.51)$$

O sinal de atuação aplicado ao sistema não-linear será:

$$u = -AB + A^{-1}v, \quad (5.52)$$

onde A e B são as matrizes anteriormente definidas e v é o sinal de atuação gerado pelo controlador linear.

Utilizando-se a equação 5.52 pode-se propagar as restrições de atuação do sinal u para o sinal de saída do controlador v realizando-se a inversa da equação 5.52 assim obtém-se:

$$V_{max} = B + AU_{max}, \quad (5.53)$$

$$V_{min} = B + AU_{min}. \quad (5.54)$$

5.4 Linearização Exata Adaptativa do Sistema de Nível de Líquidos

Aplicando a Linearização Exata no sistema de nível de líquidos tem-se o seguinte diagrama de blocos resultante, mostrado na figura 5.4.

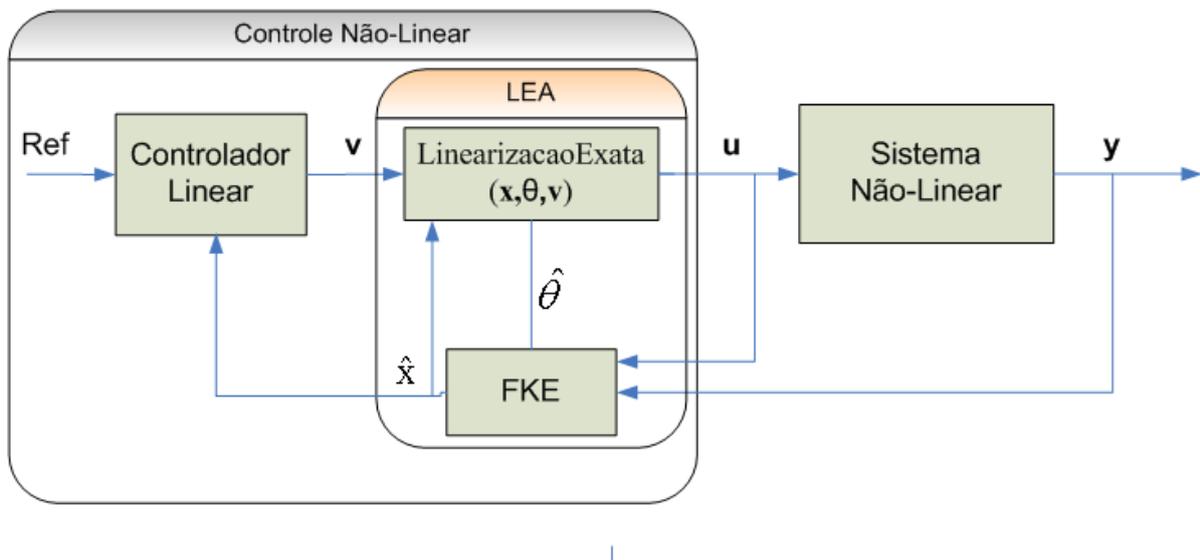


Figura 5.4: Diagrama de Blocos Linearização Exata do Sistema de Nível de Líquidos

A parte estática não-linear da linearização exata adaptativa possui a seguinte assinatura:

$$\mathbf{u} = f(\mathbf{x}, \theta, v), \quad (5.55)$$

a LEA é formada pela associação entre o FKE, apresentado no capítulo 4 e a LE, demonstrada na seção 5.2. A atualização dos parâmetros do sistema θ pode ser feita a uma taxa de amostragem múltipla da taxa de amostragem do FKE, assim pode-se evitar problemas de estabilidade do conjunto. O estudo da estabilidade desta abordagem de linearização exata adaptativa está fora do escopo deste trabalho. A linearização exata de sistema de nível de líquido já aplicada em

[Gosmann 2002] e aplicação do FKE num sistema físico semelhante foi aplicado em simulações e experimentos práticos em [Freitas, Borges e Bauchspiess 2004]. Com esta associação procura-se obter uma estratégia de controle de sistemas não-lineares baseada na aplicação de técnicas de controle linear.

O controle de um sistema não-linear com a linearização exata adaptativa tem forma de controlador não-linear, mas com todas as vantagens do controle de sistemas lineares, aplicando-se assim estratégias de controle linear, caso mais estudo em cursos de graduação e conhecido pelos Engenheiros com os sistemas físicos reais.

A associação da linearização exata adaptativa com o sistema de nível de líquido gera o seguinte modelo linear:

$$\dot{\mathbf{z}} = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \mathbf{z} + \begin{bmatrix} 1 & 0 \\ 0 & 0 \\ 0 & 1 \\ 0 & 0 \end{bmatrix} \mathbf{v} \quad (5.56)$$

$$\mathbf{y} = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \mathbf{z}.$$

Nota-se que o modelo 5.56 apresenta dois sistemas lineares desacoplados com a seguinte função de transferência $G(s) = \frac{1}{s^2}$, ou seja, uma cadeia com dois integradores. A desacoplagem do sistema de nível facilita aplicações de técnicas de controle linear aplicadas a sistemas SISO, pois tem-se dois sistemas SISO desacoplados e não mais um sistema MIMO acoplado. Assim pode-se representar o sistema do conjunto LEA + Sistema de Nível como dois sistemas com o seguinte modelo:

$$\dot{\mathbf{z}} = \begin{bmatrix} 0 & 0 \\ 1 & 0 \end{bmatrix} \mathbf{z} + \begin{bmatrix} 1 \\ 0 \end{bmatrix} v \quad (5.57)$$

$$y = \begin{bmatrix} 0 & 1 \end{bmatrix} \mathbf{z},$$

ou seja:

$$\begin{aligned} \dot{z}_1 &= v_1 \\ \dot{z}_2 &= z_1 \\ y_1 &= z_2, \end{aligned} \quad (5.58)$$

$$\begin{aligned} \dot{z}_3 &= v_2 \\ \dot{z}_4 &= z_3 \\ y_2 &= z_4, \end{aligned} \quad (5.59)$$

5.5 Conclusões

A Linearização Exata Adaptativa como estratégia que possibilita a aplicação direta de técnicas de controle linear a sistemas não-lineares foi apresentada neste capítulo, sendo que o estimador sub-ótimo foi apresentado no capítulo 4. Assim com a linearização exata associada a um estimador

de estados e parâmetros de um sistema não-linear tem-se a linearização exata adaptativa que possui os valores dos parâmetros da função não-linear alterados pelo estimador do processo.

Acredita-se que este processo pode ser eficiente para diversos sistemas, pois a aplicação da Linearização Exata é uma alternativa consistente e eficiente que foi bastante estudada desde os anos 80, como apresenta [Isidori 1989], e com o auxílio de estimadores pode-se eliminar sua principal desvantagem e aplicar a sistemas de parâmetros variantes no tempo e mesmo a sistemas de parâmetros invariantes no tempo, mas onde não se tem o valor exato no momento de projeto do controlador.

Como resultado da LEA tem-se um sistema linear que pode ser controlado por técnicas bastante conhecidas e estudadas. Porém neste trabalho aspectos importantes no estudo de controle adaptativo como: garantia de convergência, estabilidade e dinâmica da adaptação não foram tratados de forma teórica, pois entende-se que estão fora do escopo deste e podem ser objeto de estudos de trabalhos futuros. Uma forma de minimizar problemas de adaptação na LEA é a utilização do FKE para estimar em tempo real somente os parâmetros que podem sofrer alterações durante o experimento. Neste contexto os parâmetros que não sofrem mudanças podem ser estimados off-line ou em experimentos específicos.

A proposta de aplicação da linearização exata adaptativa a um sistema não-linear é baseada nos seguintes passos:

1. Ajuste e validação do estimador de estados e parâmetros;
2. Aplicação do estimador e ajuste dos valores iniciais do filtro para os estimados;
3. Alteração do conjunto de parâmetros que será estimado em tempo real para o conjunto mínimo necessário;
4. Aplicação da linearização exata ao sistema;
5. Escolha da taxa de atualização dos parâmetros estimados para a linearização exata;
6. Validação dos resultados.

Capítulo 6

Controle Preditivo Baseado em Modelo

Introdução

O controle preditivo de processos se enquadra nas técnicas de controle ótimo como mostra Imsland em et al. [Imsland, Bar e Foss 2005], pois possui uma função de custo a ser otimizada. Além da função de custo o controle preditivo possui outros componentes básicos, um modelo do processo, um comportamento básico das predições e o horizonte deslizante de predição e controle [Camacho e Bordons 2003, Rossiter 2003].

O controle preditivo é baseado num modelo processo, modelo este que é utilizado para verificar o que acontecerá com o processo num determinado horizonte [Clark, Mohtadi e Tuffs 1987, Clark, Mohtadi e Tuffs 1987] e é um importante fator do controle preditivo, pois só se consegue um bom controle se houver um bom modelo de predições, ou seja o resultado do seu controle depende diretamente do modelo utilizado, bem como da função otimização, do horizonte de predição e outros fatores. A Figura 6.1 apresenta o horizonte deslizante (*recending horizon*) utilizado em controle preditivo que será atualizado em cada instante de amostragem pelo preditor do sistema.

Uma grande vantagem do controle preditivo é a capacidade de considerar na função de otimização as diversas restrições do processo a ser controlado, como limites de entrada e saídas, limites nos estados e capacidade de variação do sinal de atuação dentre outras restrições. Em ambientes industriais essa característica é bastante utilizada e importante [Findeisen 2002] para aplicações nas mais diversas áreas, como indústria química, economia e processos industriais em geral.

Existem diversas abordagens e algoritmos de controladores preditivos como mostra a Tabela 6.1¹. A maioria dos algoritmos de controle preditivo baseados em modelos é bastante similar com algumas distinções na modelagem e predição. Existem também diferenças no uso ou não de filtros ou mesmo na substituição do sinal de referência como forma de atuação do controle preditivo, como nos trabalhos de [Bemporad 1997, Bauchspiess, Alfaro e Dobrzanski 2001]. Neste trabalho utiliza-se o Controle Preditivo baseado no *Generalized Predictive Control* (GPC) de [Clarke, Mohtadi e Tuffs 1987].

¹Os termos estão em inglês porque são mais conhecidos neste idioma.

Tabela 6.1: Algoritmos de Controle Preditivo

Sigla	Algoritmo
DMC	Dynamic Matrix Control
GPC	Generalized Predictive Control
GPCI	Generalized Predictive Control with an internal model
GPCT	Generalized Predictive Control with a T-Filter
IHPC	Infinite Horizon Predictive Control
IMC	Internal Model Control
LQMPC	Linear Quadratic optimal Model Predictive Control
PFC	Predictive Funcional Control
UPC	Unified Predictive Control
FMP	Following Model Predictive control

6.1 Controle Preditivo

O Controle Preditivo Baseado em Modelo é um algoritmo de controle multivariável que tem os seguintes módulos:

- Um modelo interno da dinâmica do processo,
- Um histórico do sinal de controle passado,
- Uma função de custo a ser otimizada sob um horizonte de predição.

A Figura 6.1 mostra os blocos funcionais de um controlador preditivo, onde os principais elementos são:

Um filtro de referências que representa o comportamento do sinal desejado para a saída no futuro. É o conhecimento prévio desta trajetória que garante ao controlador uma característica antecipativa.

O modelo do sistema é o modelo matemático interno do processo que deve ser capaz de representar o seu comportamento dinâmico de forma suficientemente precisa. Conforme a necessidade este modelo pode ser linear ou não-linear e podendo, ainda, ser atualizado através de métodos de identificação on line conferindo ao controlador uma característica adaptativa. A estrutura apresentada na Figura 2.1 apresentada um controlador com função interna não-linear, enquanto o controle preditivo desse trabalho é baseado no modelo linear obtido após a aplicação da linearização exata adaptativa no modelo não-linear do processo. A formulação matemática da linearização exata foi apresentada no Capítulo 5

O preditor tem como função fornecer através do modelo matemático uma previsão da saída futura com base na informação atual da planta.

O otimizador realiza a minimização da função custo a cada período de amostragem de forma a obter uma ação de controle que garanta um desempenho adequado ao sistema. A função a

ser minimizada pode contemplar, além de parcelas associadas ao erro futuro e ao incremento no sinal de controle, outros termos que forneçam ao controlador propriedades que melhorem o seu desempenho frente às particularidades do processo. Quando da utilização de uma função custo quadrática, modelos lineares e na ausência de restrições o problema de otimização apresenta uma solução analítica, caso contrário, algum método de otimização numérica deve ser empregado.

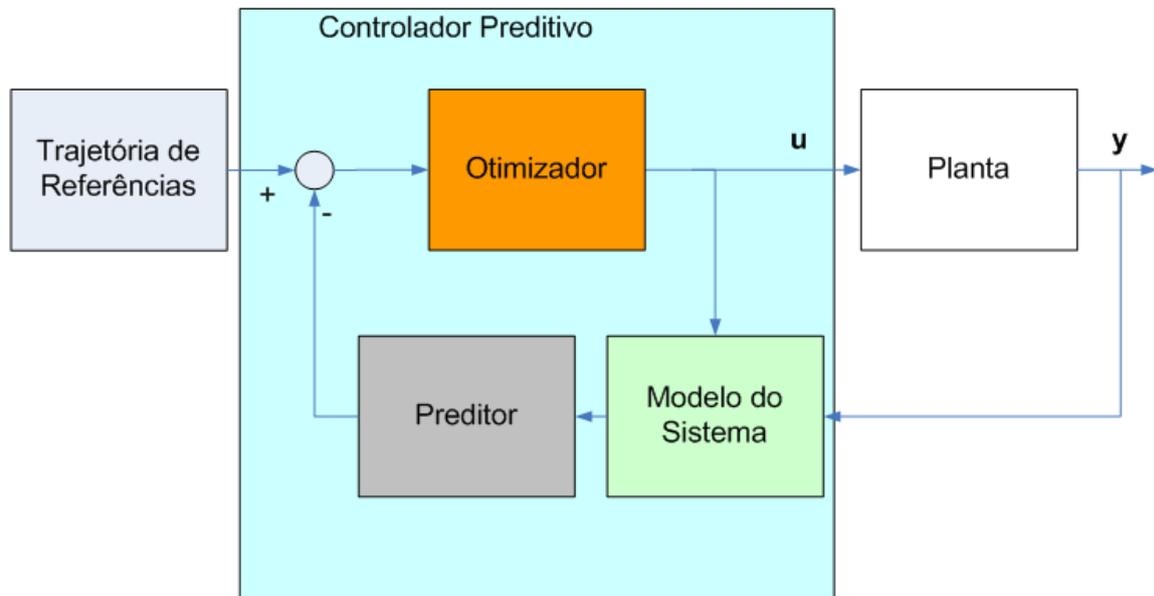


Figura 6.1: Estrutura de um controlador preditivo

O Controle Preditivo considera, de forma explícita, as restrições de um sistema. Estas podem ser restrições nos estados ou na saída do controlador. A função de custo a ser minimizada no controle preditivo utiliza um horizonte de controle para atingir o valor desejado de referência, minimizando o sinal de atuação e gera como resultado mais de um sinal de atuação, dentro do horizonte de controle que atingirá o sinal de referência dentro do horizonte de predição. Assim o primeiro sinal é aplicado ao sistema e novamente recalcula-se os sinais de saída do controle preditivo a cada instante de amostragem.

O formato geral de um preditor é:

$$\mathbf{y}_{\rightarrow k} = H \Delta \mathbf{u}_{\rightarrow k-1} + P \mathbf{x}_{\leftarrow k}, \quad (6.1)$$

onde H é a matriz Toeplitz $C_{G/\Delta}$ da resposta ao degrau do sistema e P depende da forma direta dos parâmetros do modelo [Rossiter 2003].

A predição pode ser feita com base em diversas técnicas as mais utilizadas são predição no espaço-de-estados e predição utilizando modelo *Controllerd Auto-Regressive Integrated Moving Average* (CARIMA) [Rossiter 2003], esta é feita com base no modelo interno do processo, ver seção 6.1.1.

A função de custo a ser otimizada possui o seguinte formato geral:

$$J = \sum_{i=n_w}^{n_y} \|W_y e_{k+1}\|_2^2 + \lambda \sum_{i=0}^{n_u} \|W_u \Delta \mathbf{u}_{k+i}\|_2^2, \quad (6.2)$$

onde:

- n_y é o horizonte de predição,
- n_u é o horizonte de controle,
- n_w é a parte do horizonte de predição onde inicia-se a predição do erro, esta pode ser bastante interessante para controle de sistemas com atraso de transporte ou mesmo sistemas de fase não mínima, como explorado em [Rossiter 2003],
- W_y matriz de pesos das saídas do sistema, caso multivariável como do sistema de nível de líquidos,
- W_u matriz de pesos dos sinais de controle do sistema, caso multivariável como do sistema de nível de líquidos.

A figura 6.1 ilustra o horizonte de predição do controle preditivo. O horizonte é dito deslizante, pois faz a predição sempre k passos a frente do instante atual e atua de forma a minimizar a ação de controle e atingir o valor desejado dentro deste horizonte.

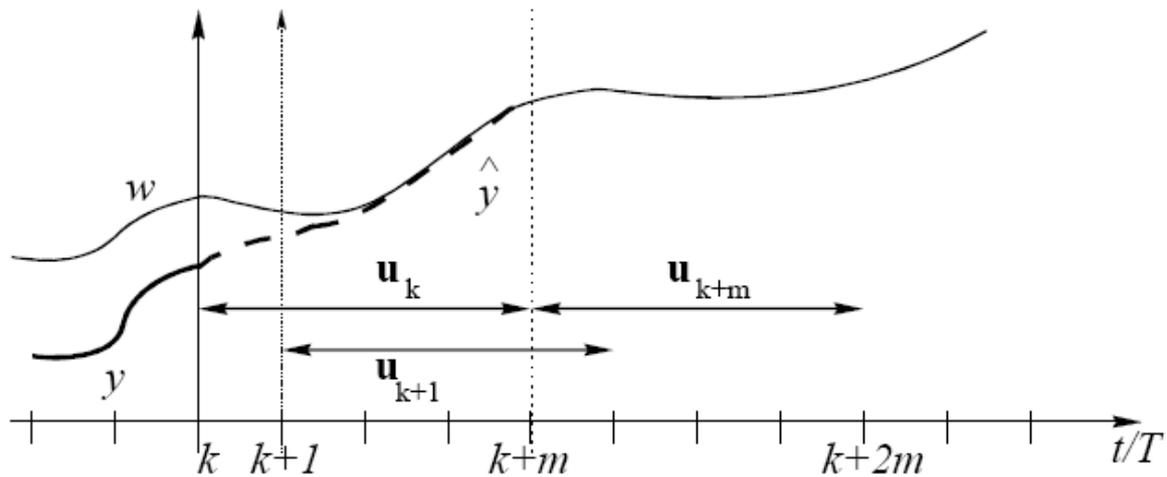


Figura 6.2: Horizonte Deslizante em Controle Preditivo

6.1.1 O Modelo Interno do Controle Preditivo

A modelagem de um processo é um passo importante no controle preditivo de sistemas. Encontrar um modelo pode ser indicativo de sucesso ou não da estratégia de controle o modelo

utilizado deve procurar ser ao mesmo tempo simples e que forneça predições acurados do processo [Rossiter 2003]. Pode-se também modelar perturbações internamente com objetivo de rejeitá-las na estratégia de controle, neste caso pode-se utilizar modelos simples e realizar evoluções com base em testes executados. Em alguns casos utiliza-se também filtros para reduzir ruído de medição, como neste trabalho utiliza-se o filtro de Kalman estendido, ver Capítulo 4 para estimar estados do sistema, não se necessita de filtragem de medidas.

Existem diversas formas de modelagem de sistemas como: resposta finita ao impulso, função de transferência, descrição matriz-fração, entre outras. A modelagem utilizada neste capítulo é baseada em modelo espaço-de-estados de sistemas. A equação 6.3 apresenta um sistema linear modelado no espaço-de-estados que servirá de base para o controle desenvolvido neste capítulo. A modelagem apresentado nesta seção segue o padrão mostrado em [Rossiter 2003]

$$\begin{cases} \mathbf{x}_{k+1} = A\mathbf{x}_k + B\mathbf{u}_k \\ \mathbf{y}_k = C\mathbf{x}_k, \end{cases} \quad (6.3)$$

com este modelo pode-se encontrar o preditor do sistema de forma recursiva utilizando a equação 6.1, assim tem-se que:

$$\mathbf{x}_{k+1} = A\mathbf{x}_k + B\mathbf{u}_k \quad (6.4)$$

$$\mathbf{x}_{k+2} = A^2\mathbf{x}_k + AB\mathbf{u}_k + B\mathbf{u}_{k+1} \quad (6.5)$$

$$\mathbf{x}_{k+3} = A^3\mathbf{x}_k + A^2B\mathbf{u}_k + AB\mathbf{u}_{k+1} + B\mathbf{u}_{k+2}, \quad (6.6)$$

logo tem-se o seguinte sistema linear ampliado:

$$\begin{bmatrix} \mathbf{x}_{k+1} \\ \mathbf{x}_{k+2} \\ \mathbf{x}_{k+3} \\ \mathbf{x}_{k+4} \\ \vdots \\ \mathbf{x}_{k+n_y} \end{bmatrix} = \begin{bmatrix} A \\ A^2 \\ A^3 \\ A^4 \\ \vdots \\ A^{n_y} \end{bmatrix} \mathbf{x}_k + \begin{bmatrix} B & 0 & 0 & \dots & 0 \\ AB & B & 0 & \dots & 0 \\ A^2B & AB & B & \dots & 0 \\ A^3B & A^2B & AB & \dots & 0 \\ \vdots & \vdots & \vdots & \dots & \vdots \\ A^{n_y-1}B & A^{n_y-2}B & A^{n_y-3}B & \dots & B \end{bmatrix} \begin{bmatrix} \mathbf{u}_k \\ \mathbf{u}_{k+1} \\ \mathbf{u}_{k+2} \\ \mathbf{u}_{k+3} \\ \dots \\ \mathbf{u}_{k+n_y-1} \end{bmatrix} \quad (6.7)$$

na forma compacta tem-se que:

$$\mathbf{x}_{\rightarrow k} = P_{xx}\mathbf{x}_k + H_x \mathbf{u}_{\rightarrow k-1}, \quad (6.8)$$

onde a saída do sistema é:

$$\begin{bmatrix} \mathbf{y}_{k+1} \\ \mathbf{y}_{k+2} \\ \mathbf{y}_{k+3} \\ \mathbf{y}_{k+4} \\ \vdots \\ \mathbf{y}_{k+n_y} \end{bmatrix} = \begin{bmatrix} CA \\ CA^2 \\ CA^3 \\ CA^4 \\ \vdots \\ CA^{n_y} \end{bmatrix} \mathbf{x}_k + \begin{bmatrix} CB & 0 & 0 & \dots & 0 \\ CAB & CB & 0 & \dots & 0 \\ CA^2B & CAB & CB & \dots & 0 \\ CA^3B & CA^2B & CAB & \dots & 0 \\ \vdots & \vdots & \vdots & \dots & \vdots \\ CA^{n_y-1}B & CA^{n_y-2}B & CA^{n_y-3}B & \dots & CB \end{bmatrix} \begin{bmatrix} \mathbf{u}_k \\ \mathbf{u}_{k+1} \\ \mathbf{u}_{k+2} \\ \mathbf{u}_{k+3} \\ \dots \\ \mathbf{u}_{k+n_y-1} \end{bmatrix}, \quad (6.9)$$

na forma compacta tem-se que:

$$\underset{\rightarrow k}{\mathbf{y}} = P_{\mathbf{x}} \mathbf{x}_k + H_{\rightarrow k-1} \mathbf{u}. \quad (6.10)$$

Assim o modelo para predição de sistemas lineares modelados no espaço-de-estados na forma compacta é:

$$\begin{cases} \underset{\rightarrow k}{\mathbf{x}} &= P_{\mathbf{xx}} \mathbf{x}_k + H_{\mathbf{x} \rightarrow k-1} \mathbf{u} \\ \underset{\rightarrow k}{\mathbf{y}} &= P_{\mathbf{x}} \mathbf{x}_k + H_{\rightarrow k-1} \mathbf{u} \end{cases} \quad (6.11)$$

6.1.2 A Minimização da Função de Custo

Utilizando a modelagem no espaço-de-estados a função definida na equação 6.2, tem-se a seguinte função de custo:

$$\min_{\mathbf{u}} J = [\underline{\mathbf{x}} - \mathbf{x}_{ss}]^T Q [\underline{\mathbf{x}} - \mathbf{x}_{ss}] + [\underline{\mathbf{u}} - \mathbf{u}_{ss}]^T R [\underline{\mathbf{u}} - \mathbf{u}_{ss}], \quad (6.12)$$

onde \mathbf{u}_{ss} é o sinal de controle em regime permanente, estado \mathbf{x}_{ss} , para a referência atual do sistema.

A minimização da função de custo original J fornece $\mathbf{u} = -K\mathbf{x}$ com a translação do ponto de operação temos tem-se que $\mathbf{u} = -K(\mathbf{x} - \mathbf{x}_{ss}) + \mathbf{u}_{ss}$. Assim como:

$$\underline{\mathbf{x}} = P_{\mathbf{xx}} \mathbf{x} - H_{\mathbf{x}} \underline{\mathbf{u}}, \quad (6.13)$$

$$\min_{\underline{\mathbf{u}}} J = [P_{\mathbf{xx}} \mathbf{x} - H_{\mathbf{x}} \underline{\mathbf{u}}]^T Q [P_{\mathbf{xx}} \mathbf{x} - H_{\mathbf{x}} \underline{\mathbf{u}}] + \underline{\mathbf{u}}^T R \underline{\mathbf{u}}, \quad (6.14)$$

$$\underline{\mathbf{u}} = -[H_{\mathbf{x}}^T Q H_{\mathbf{x}} + R]^{-1} H_{\mathbf{x}}^T Q P_{\mathbf{xx}} \mathbf{x}, \quad (6.15)$$

assim tem-se que:

$$\mathbf{u}_k - \mathbf{u}_{ss} = -\mathbf{e}_1^T [H_{\mathbf{x}}^T Q H_{\mathbf{x}} + R]^{-1} H_{\mathbf{x}}^T Q P_{\mathbf{xx}} (\mathbf{x} - \mathbf{x}_{ss}). \quad (6.16)$$

6.2 Aplicação do MPC ao Sistema de Nível Multivariável

Utilizando o modelo obtido pela linearização exata do processo temos um controle como mostra a Figura 6.2. O modelo do processo utilizado no controlador preditivo é um modelo linear, mas a ação de controle preditivo à qual o sistema não-linear está sujeito é uma ação de controle preditivo não-linear, devido a ação conjunta do controle preditivo baseado em modelo com a linearização exata adaptativa. O modelo interno utilizado é o modelo obtido pela linearização exata do sistema de nível de líquidos, descrito no Capítulo 5:

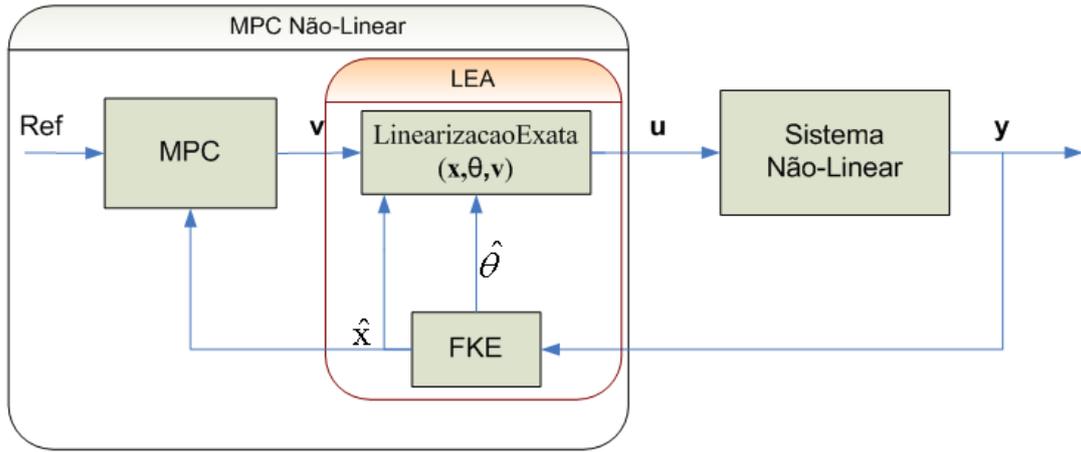


Figura 6.3: Diagrama de Blocos da Linearização Exata Adaptativa com Controle Preditivo

$$\begin{aligned}
 A &= \begin{bmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}, \\
 B &= \begin{bmatrix} 1 & 0 \\ 0 & 0 \\ 0 & 1 \\ 0 & 0 \end{bmatrix}, \\
 C &= \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix},
 \end{aligned} \tag{6.17}$$

assim aplica-se um controlador preditivo multivariável, mas com a desacoplagem do sistema de nível gerando dois sub-sistemas na forma de cadeia de integradores pode-se utilizar dois controladores preditivos, um para cada sub-sistema, neste caso o modelo interno de cada controlador é:

$$\begin{aligned}
 A &= \begin{bmatrix} 0 & 0 \\ 1 & 0 \end{bmatrix}, \\
 B &= \begin{bmatrix} 1 \\ 0 \end{bmatrix}, \\
 C &= \begin{bmatrix} 0 & 1 \end{bmatrix}.
 \end{aligned} \tag{6.18}$$

Substituindo-se estes modelos nas equações predição tem-se a forma de predição para o conjunto MPC + LE + FKE. Nota-se que devido à simplicidade do modelo produzido pela linearização exata do sistema de nível de líquidos do LAVSI.

6.3 Conclusões

Este capítulo apresentou um resumo sobre controle preditivo baseado em modelo e sua associação com a linearização exata adaptativa.

Em relação ao controle preditivo mostrou-se seus componentes principais e funcionalidade, bem como uma lista de diversas abordagens de controle preditivo linear, ver tabela 6.1. A seção 6.1 apresentou a estrutura básica e o formato genérico de um preditor.

A modelagem no espaço-de-estados foi estratégia utilizada para apresentar o modelo interno do controle preditivo baseado em modelo e uma função de custo geral foi descrita na sub-seção 6.1.2. Ao final foi apresentado a forma associada do controlador preditivo com a linearização exata adaptativa aplicada ao sistema de nível de líquido com os modelos que devem ser utilizados no modelo interno do controlador.

Capítulo 7

Resultados Obtidos

Este Capítulo apresenta resultados experimentais da aplicação do filtro de Kalman estendido, da linearização exata e da linearização exata adaptativa para o sistema de nível de líquidos do LAVSI.

Introdução

Os resultados apresentados nesse capítulo são resultados de simulações das situações indicadas, assim sabe-se os valores corretos das posições das válvulas do processo, além dos corretos valores das variáveis de estado. A simulação do Processo de Nível Líquidos foi realizada utilizando o método de Euler para simulação, Freitas et al. em [Freitas, Borges e Bauchspiess 2004] foram apresentados resultados do controle do processo real e simulações baseadas no método de Euler e os resultados estavam coerentes com as simulações realizadas. Esta foi realizada com um intervalo de integração 10 vezes a frequência de controle do processo simulado, assim temos uma simulação bastante rápida num método pouco eficiente, mas devido a alta taxa de simulação pode-se considerar os resultados como satisfatórios [Franklin, Powell e Workman 1997].

A aplicação de filtro de Kalman estendido como estimador de estados e parâmetros será apresentada com experimentos em malha aberta e em malha fechada, ambos com variações dos parâmetros durante os experimentos, assim pode-se observar a capacidade e qualidade da estimação conjunta do FKE para o sistema de nível de líquidos.

As simulações realizadas incluem nas medidas um ruído gaussiano de variância de 1,5, tendo em vista que os sensores capacitivos utilizados no sistema de nível de líquidos possuem precisão de 0,5mm [Bernardes et al. 2006] este valor pode ser considerado bom para simular os sensores em uso no sistema real.

7.1 Estimação de Estados e Parâmetros com o Filtro de Kalman Estendido em Malha Aberta

A aplicação do FKE para estimar os estados e parâmetros do sistema de nível de líquido foi apresentada de forma teórica no Capítulo 4 e nesta seção apresenta-se resultados da estimação

conjunta de estados e parâmetros do sistema. Os sinais de entrada mostrados na Figura 7.1 foram aplicados no sistema de nível em malha aberta, com mudança nas válvulas durante a operação. A Figura 7.2 mostra os valores estimados dos estados para a entrada da Figura 7.1 e a Figura 7.3 apresenta os resíduos de estimação dos estados no intervalo de confiança $\pm 3\sigma$.

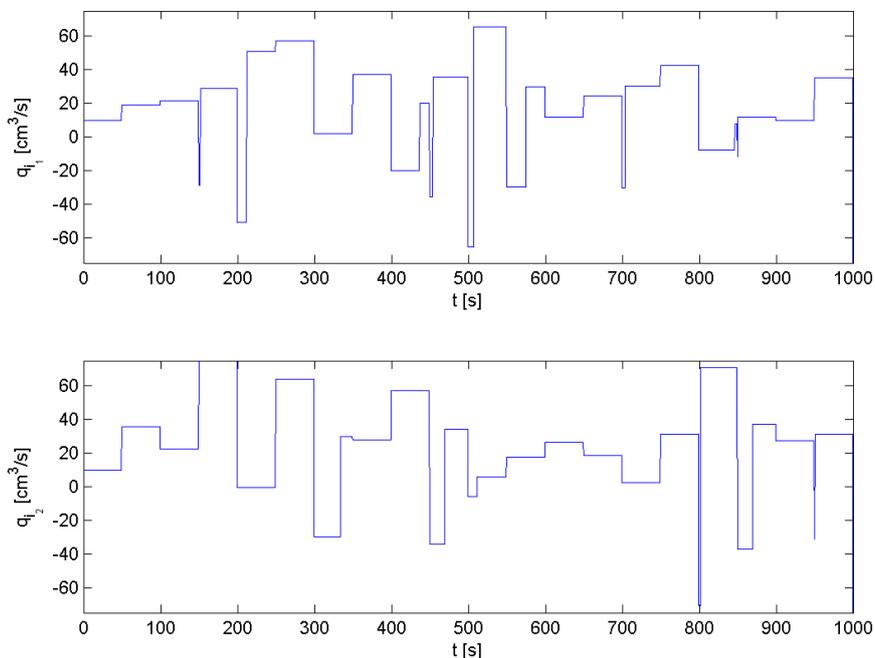


Figura 7.1: Sinal dos Atuadores em Malha Aberta

A Figura 7.4 mostra o resultado da estimação dos parâmetros k_{12} , k_{23} e k_{34} do modelo não-linear do sistema de nível, equação 3.12. Note que os valores dos parâmetros k_{12} , k_{23} e k_{34} sofrem alterações durante a operação e o FKE consegue acompanhar tal variação. As Tabelas 7.1, 7.2 e 7.3 apresentam os valores dos parâmetros k_{12} , k_{23} e k_{34} alterados em função do tempo.

A Figura 7.1 mostra o resultado da estimação dos parâmetros k_2 e k_4 do modelo não-linear do sistema de nível, equação 3.12. Estes parâmetros não foram testados com mudanças durante a operação, pois se tratam dos furos nos tanques 2 e 4, assim não se tem mudança durante um experimento.

Tabela 7.1: Alterações no valor de k_{12}

Instante de Tempo (s)	Valor real de k_{12}
0	12,12
300	13,332
700	14,665

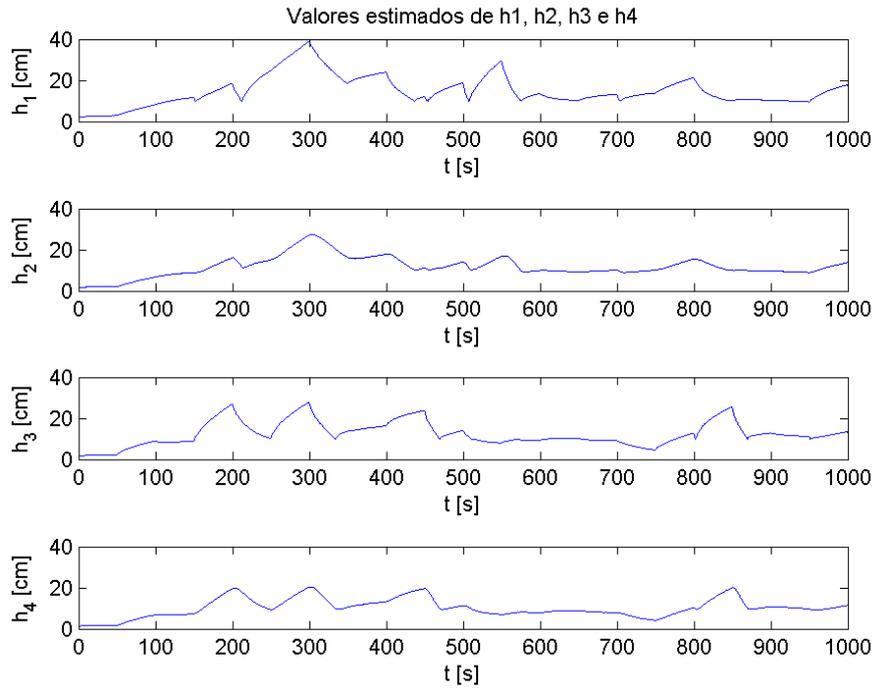


Figura 7.2: Valores Estimados dos Estados em Malha Aberta

Tabela 7.2: Alterações no valor de k_{23}

Instante de Tempo (s)	Valor real de k_{23}
0	4,49
200	4,04
600	3,23
800	4,20

Tabela 7.3: Alterações no valor de k_{34}

Instante de Tempo (s)	Valor real de k_{34}
0	16,88
400	18,57
900	20,42

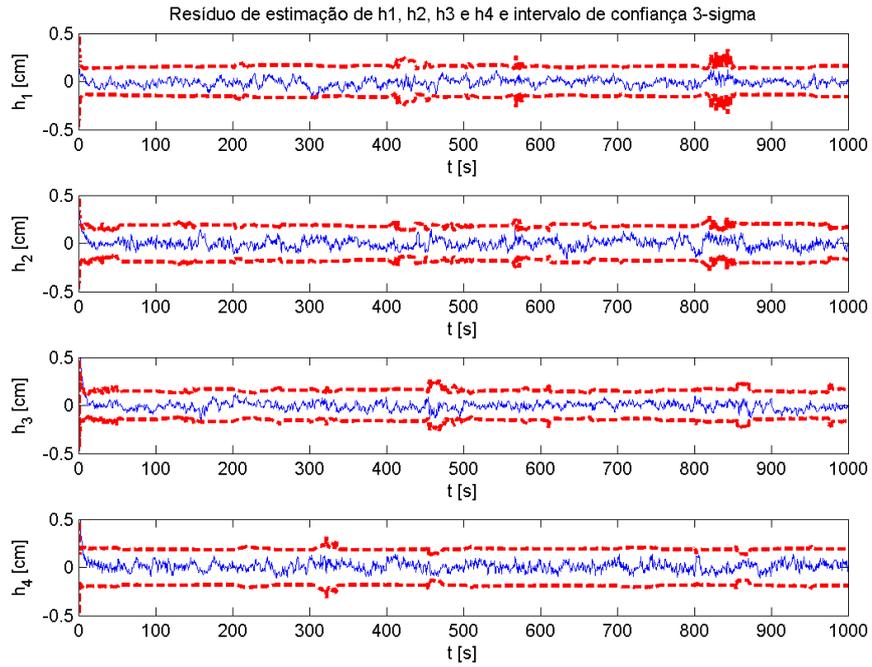


Figura 7.3: Resíduos de Estimação dos Estados em Malha Aberta

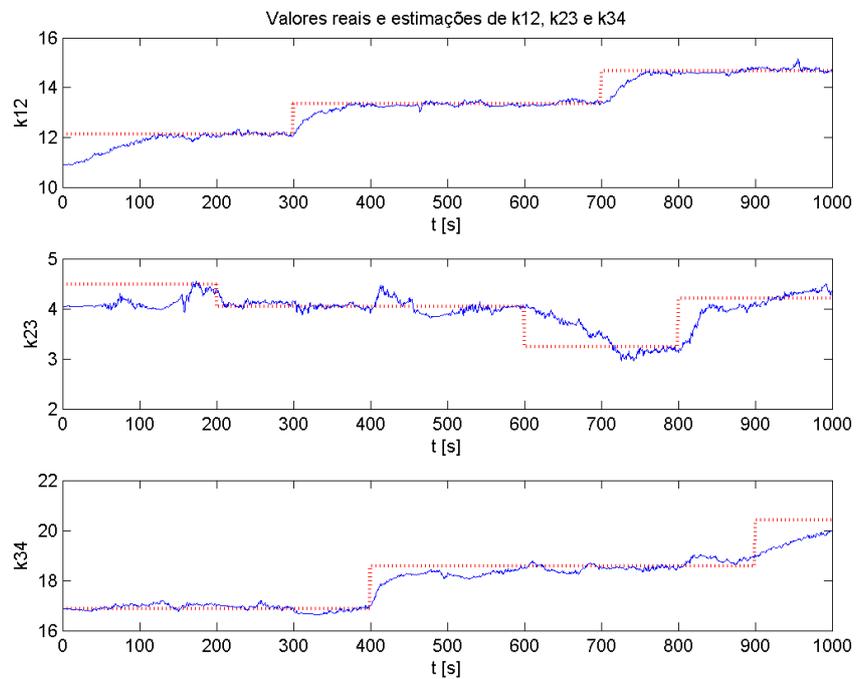


Figura 7.4: Valores Reais e Estimação de k_{12} , k_{23} e k_{34} em Malha Aberta

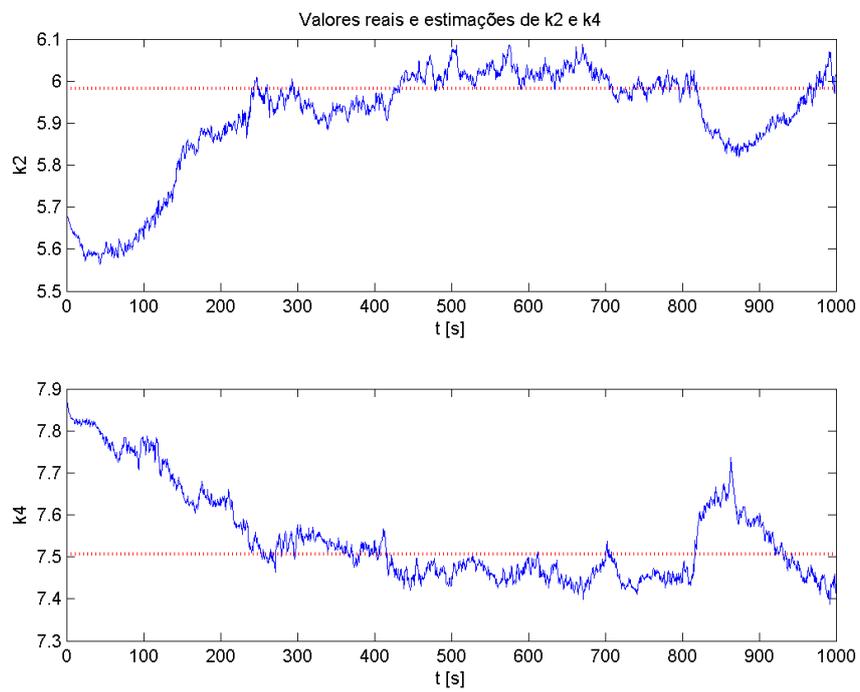


Figura 7.5: Valores Reais e Estimação de k_2 e k_4 em Malha Aberta

7.2 Aplicação da LEA ao Sistema de Nível de Líquidos

A linearização exata adaptativa facilita o controle de sistemas não-lineares de forma independente do ponto de operação, assim como para grandes sinais. No caso do sistema de nível de líquidos apresenta-se um resultado da referência variando 20 cm, na forma de onda quadrada, assim mostra-se a aplicação do conjunto linearização exata com filtro de Kalman estendido aplicado a grandes sinais. Neste caso a atualização dos parâmetros para a linearização exata ocorre a cada dez instantes de amostragem e não a cada instante de atuação do controlador.

Os sinais de entrada mostrados na Figura 7.7 são a saída do controlador PI que será uma das entradas da linearização exata, juntamente com os estados e parâmetros estimados pelo FKE. A Figura 7.8 mostra os valores estimados dos estados o controle PI utilizando a linearização exata adaptativa e a Figura 7.9 apresenta os resíduos de estimação dos estados no intervalo de confiança $\pm 3\sigma$. Os valores utilizados no controlador foram $P = 0,5$ e $I = 0,001$.

O diagrama de blocos da Figura 7.6 apresenta a estrutura desse controlador, onde pode-se observar que o PI mesmo contante e linear é percebido pelo sistema como um controlador não-linear.

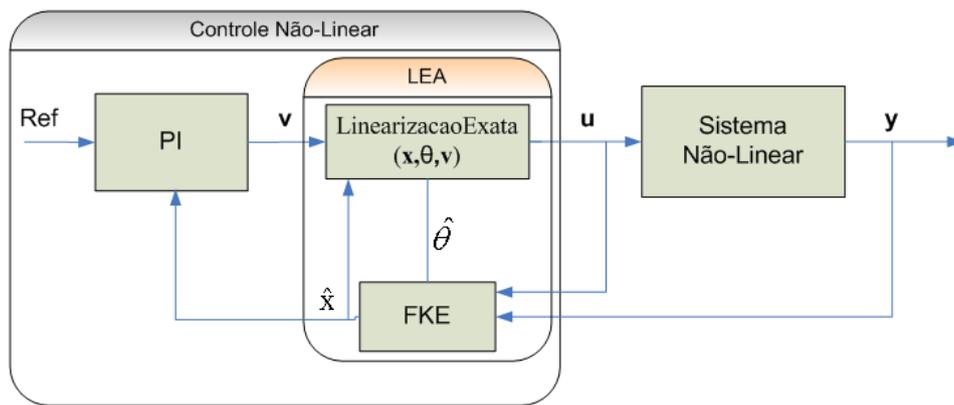


Figura 7.6: Diagrama de blocos do associação entre a LEA com o controle PI

A Figura 7.10 mostra o resultado da estimação dos parâmetros k_{12} , k_{23} e k_{34} do modelo não-linear do sistema de nível, equação 3.12. Note que os valores dos parâmetros k_{12} , k_{23} e k_{34} sofrem alterações durante a operação e o FKE consegue acompanhar tal variação, a alteração é a mesma do experimento em malha aberta. A Figura 7.11 mostra o resultado da estimação dos parâmetros k_2 e k_4 do modelo não-linear do sistema de nível, equação 3.12.

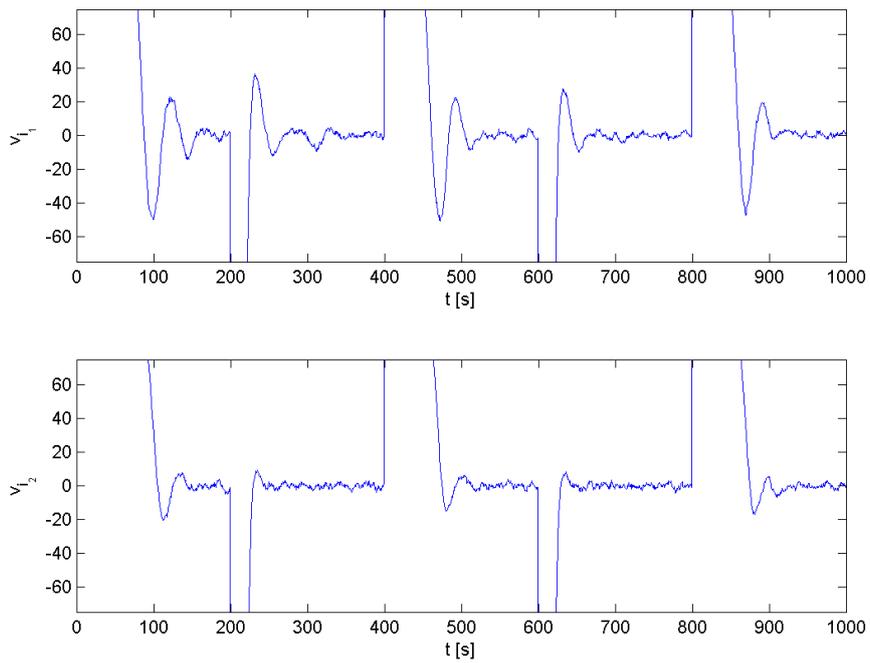


Figura 7.7: Sinal dos Atuadores - LEA com controle PI

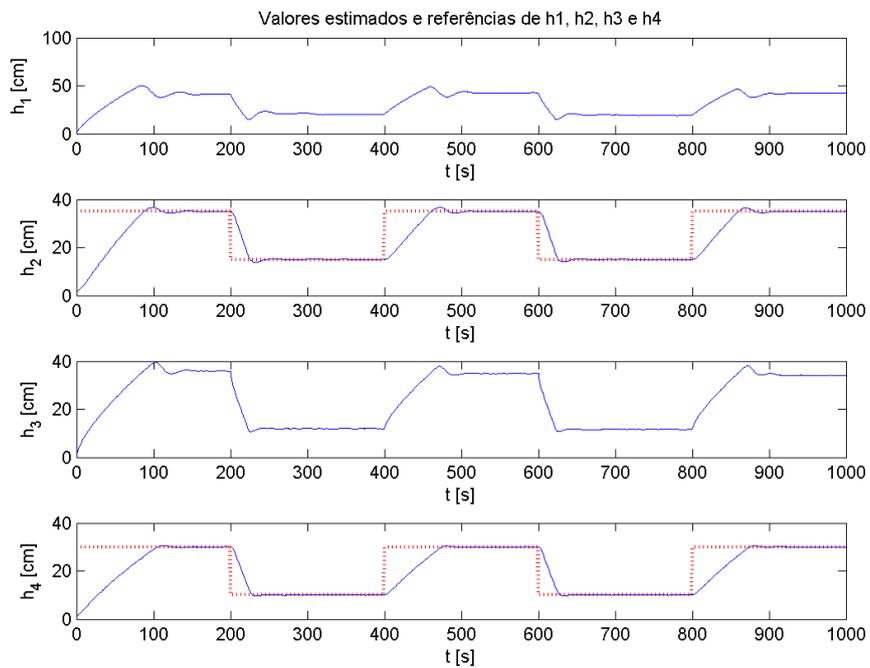


Figura 7.8: Valores estimados dos estados - LEA com controle PI

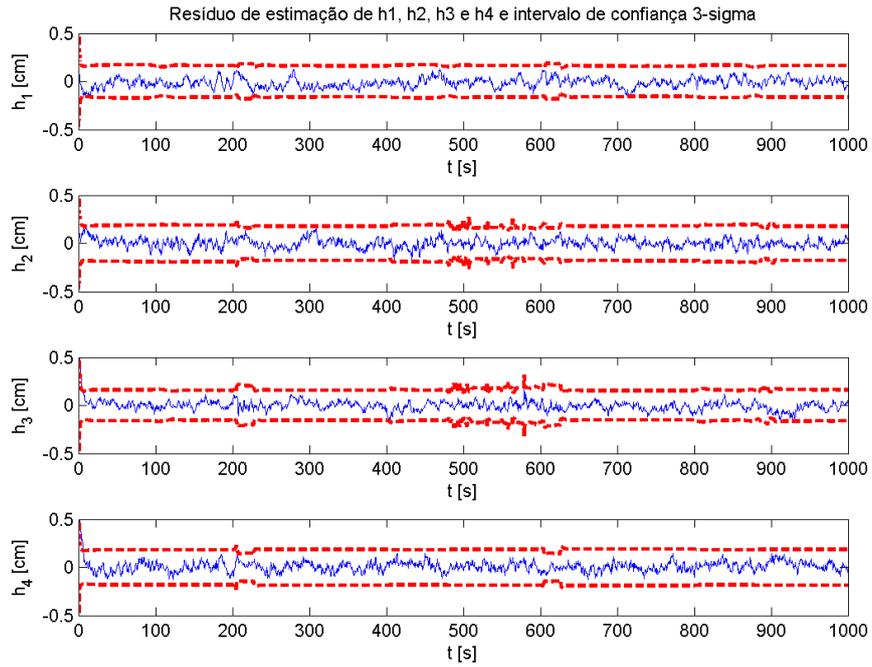


Figura 7.9: Resíduos de estimação dos estados - LEA com controle PI

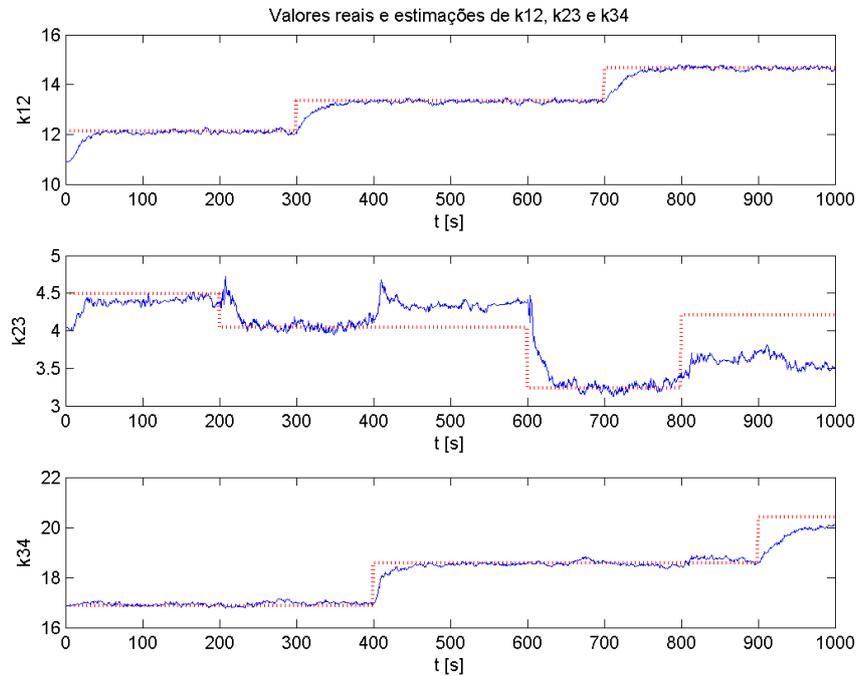


Figura 7.10: Valores reais e estimados de k_{12} , k_{23} e k_{34} - LEA com controle PI

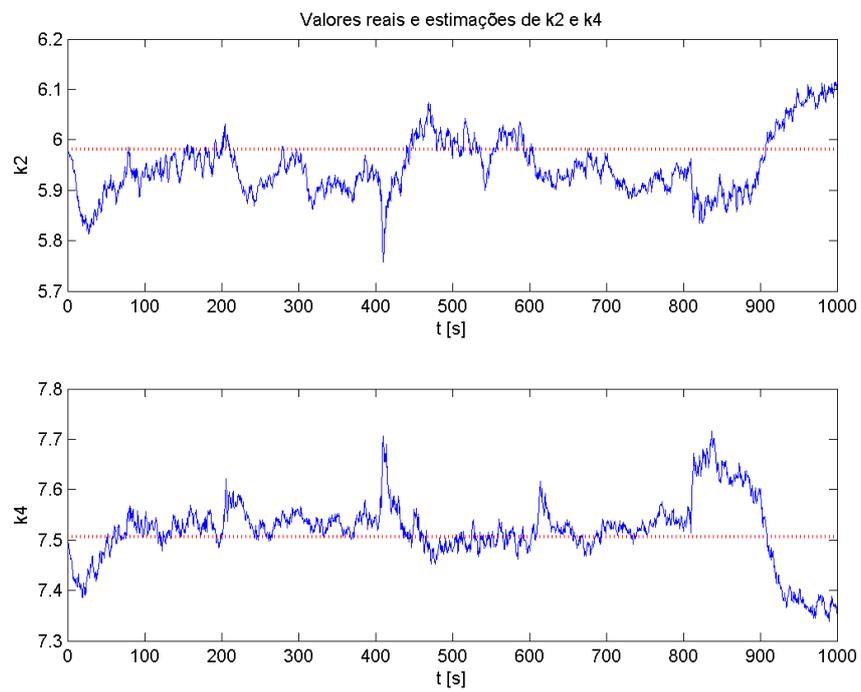


Figura 7.11: Valores reais e estimados de k_2 e k_4 - LEA com controle PI

7.3 Aplicação de Controle Preditivo com LEA ao Sistema de Nível de Líquidos

O controle preditivo de processos é juntamente com as derivações do PID o par de técnicas de controle com maior uso industrial, mas o controle preditivo possui grande uso e aceitação acadêmica também, tornando-se possuidor de uma combinação única entre indústria e pesquisa acadêmica. Assim torna bastante interessante aplicar o MPC ao sistema de nível de líquidos. O modelo interno utilizado é o modelo obtido pela linearização exata do sistema de nível de líquidos:

$$\dot{\mathbf{x}} = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \mathbf{x} + \begin{bmatrix} 1 & 0 \\ 0 & 0 \\ 0 & 1 \\ 0 & 0 \end{bmatrix} v, \quad (7.1)$$

$$\mathbf{y} = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \mathbf{x}$$

assim aplica-se um controlador preditivo multivariável, mas com a desacoplagem do sistema de nível gerando dois sub-sistemas na forma de cadeia de integradores pode-se utilizar dois controladores preditivos, um para cada sub-sistema, neste caso o modelo interno de cada controlador é:

$$\dot{\mathbf{x}} = \begin{bmatrix} 0 & 0 \\ 1 & 0 \end{bmatrix} \mathbf{x} + \begin{bmatrix} 1 \\ 0 \end{bmatrix} v. \quad (7.2)$$

$$y = \begin{bmatrix} 0 & 1 \end{bmatrix} \mathbf{x}$$

O diagrama de blocos da Figura 7.12 apresenta a estrutura desse controlador, onde pode-se observar que o MPC atua como se fosse um NMPC, devido a parte não-linear da linearização exata adaptativa. Assim tem-se as vantagens do projeto de controladores lineares aplicado a sistemas reais.

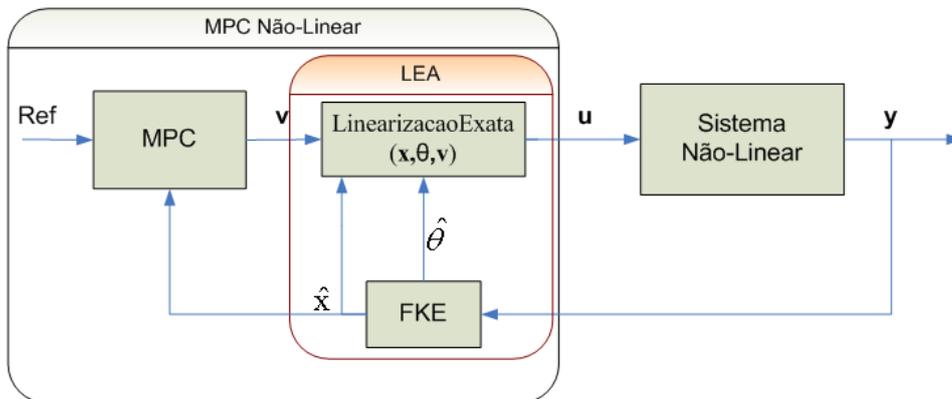


Figura 7.12: Diagrama de blocos da associação entre a LEA com o controle MPC

A linearização exata adaptativa facilita o controle de sistemas não-lineares de forma independente do ponto de operação, assim como para grandes sinais. No caso do sistema de nível de líquidos apresenta-se um resultado da referência variando 20 cm, na forma de onda quadrada, assim mostra-se a aplicação do conjunto linearização exata com filtro de Kalman estendido aplicado a grandes sinais. Neste caso a atualização dos parâmetros para a linearização exata ocorre a cada dez instantes de amostragem e não a cada instante de atuação do controlador.

A Figura 7.13 mostra os valores estimados dos estados no experimento com controlador MPC utilizando a linearização exata adaptativa e a Figura 7.14 apresenta os resíduos de estimação dos estados no intervalo de confiança 3σ .

A Figura 7.15 mostra o resultado da estimação dos parâmetros k_{12} , k_{23} e k_{34} pelo FKE e seus valores reais que sofrem alterações durante a execução do experimento. A Figura 7.16 mostra o resultado da estimação dos parâmetros k_2 e k_4 pelo filtro de Kalman estendido.

Os sinais de entrada mostrados na Figura 7.17 são a saída do controlador MPC que será uma das entradas da linearização exata, juntamente com os estados e parâmetros estimados pelo FKE.

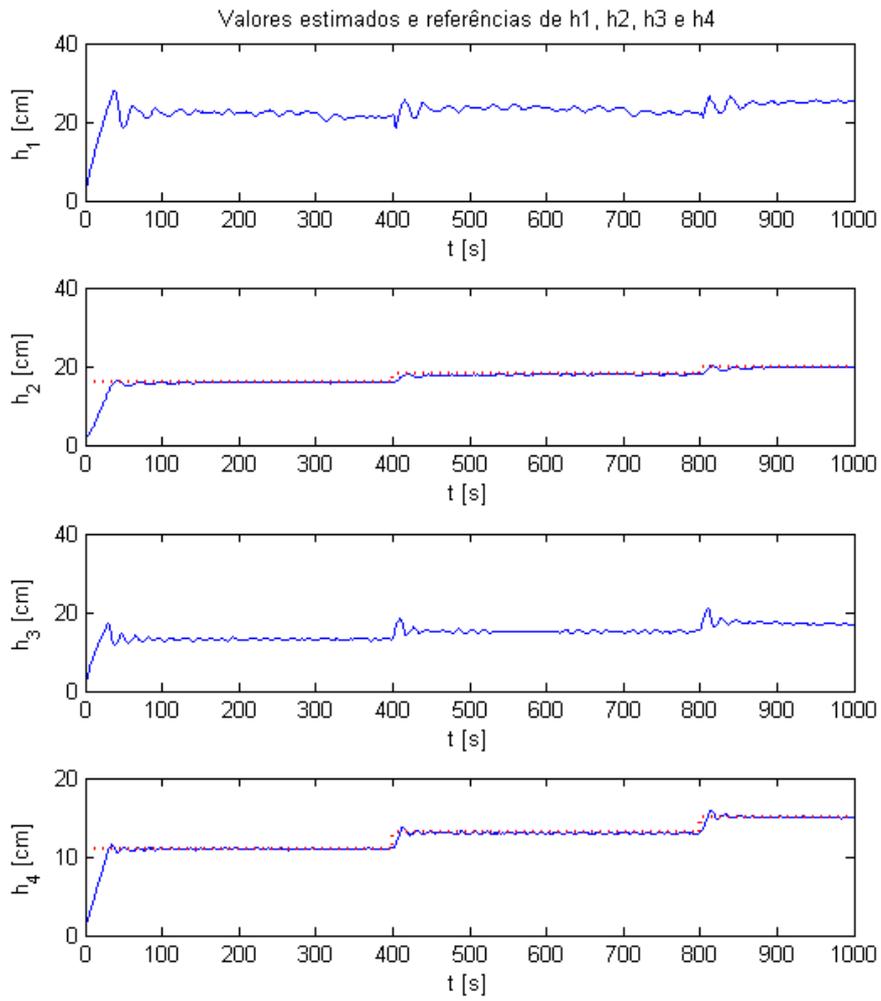


Figura 7.13: Valores estimados dos estados - LEA controle MPC

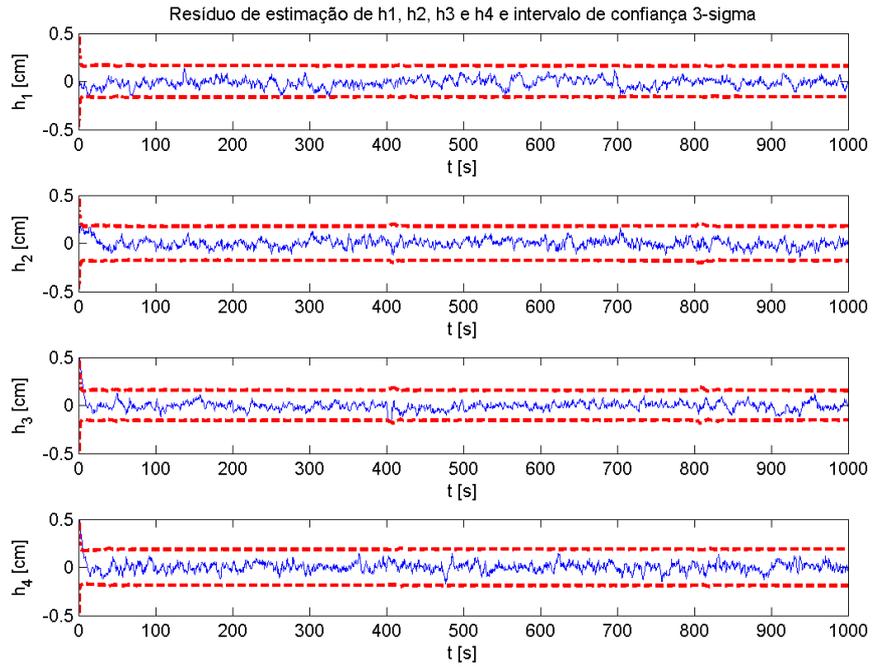


Figura 7.14: Resíduos de estimação dos estados - LEA controle MPC

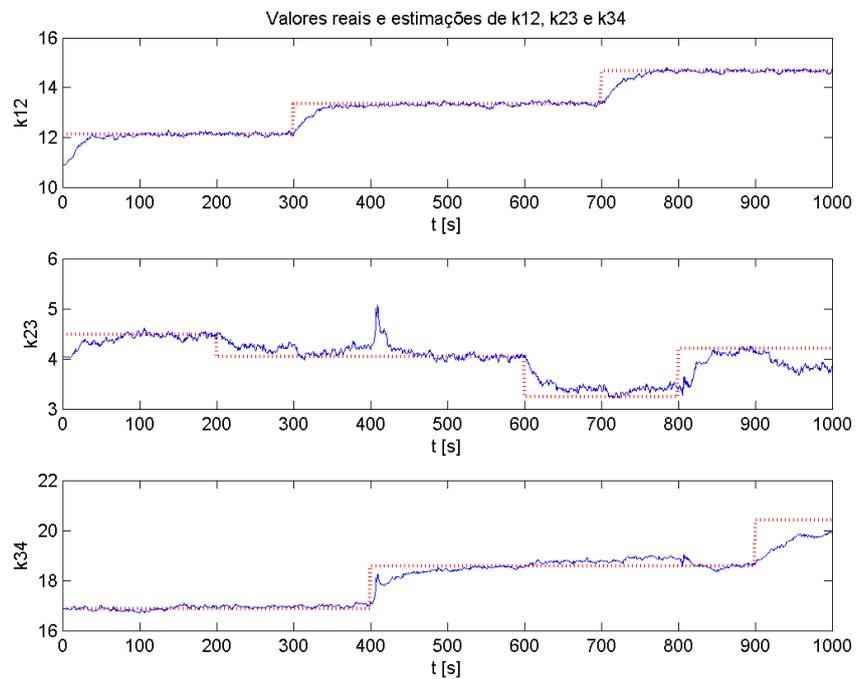


Figura 7.15: Valores reais e estimados de k_{12} , k_{23} e k_{34} - LEA controle MPC

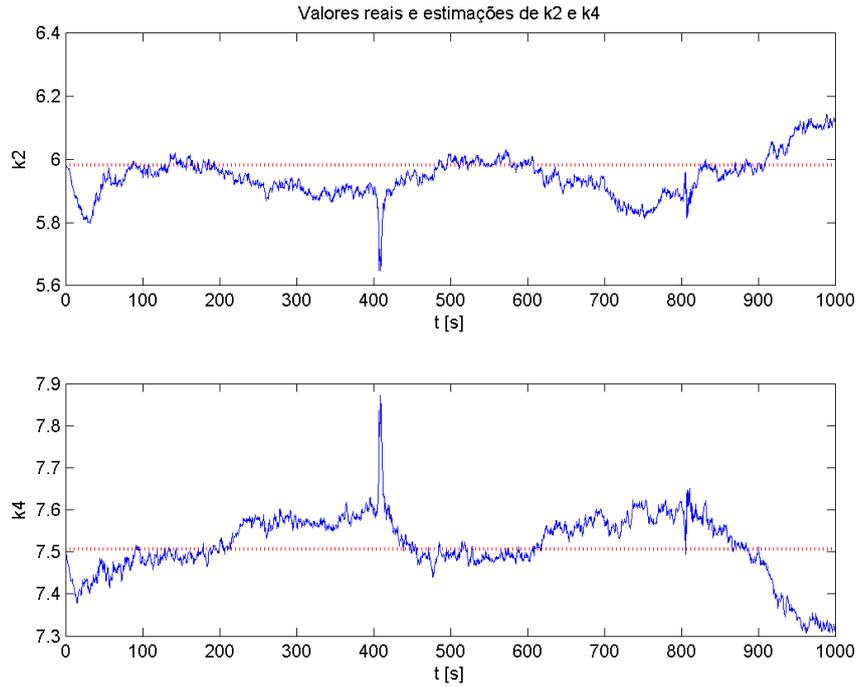


Figura 7.16: Valores reais e estimados de k_2 e k_4 - LEA controle MPC

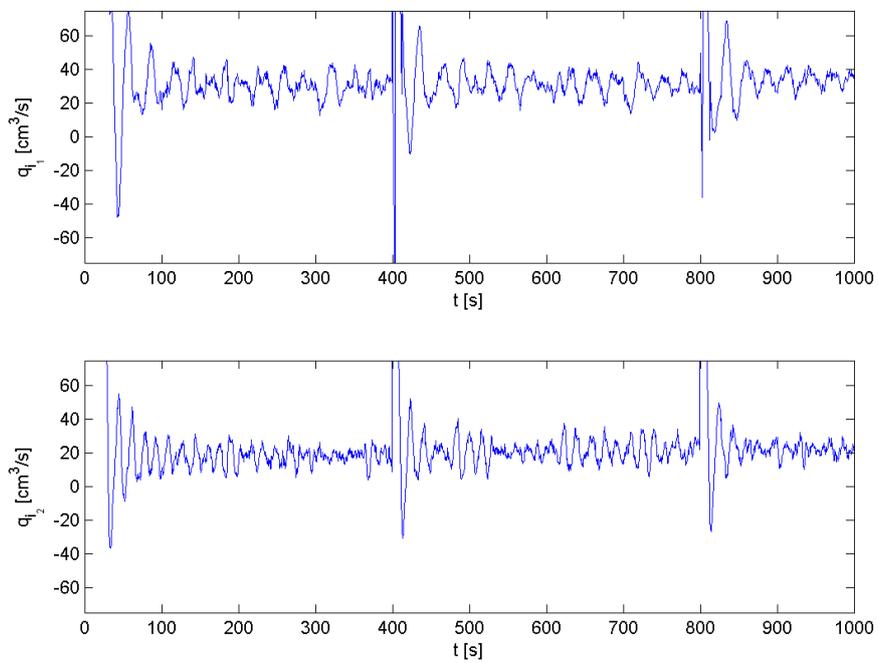


Figura 7.17: Sinal dos atuadores - LEA controle MPC

A Figura 7.18 apresenta o controle MPC associado a linearização exata adaptativa sendo executado em toda a faixa de operação do sistema de nível de líquidos. Nota-se que no controle do nível do tanque 2 para valores altos de referência possui uma certa oscilação. Mas neste caso o fator predominante é a altura máxima do nível que está próximo do seu valor limite gerando um sinal de atuação mais ruidoso que o normal.

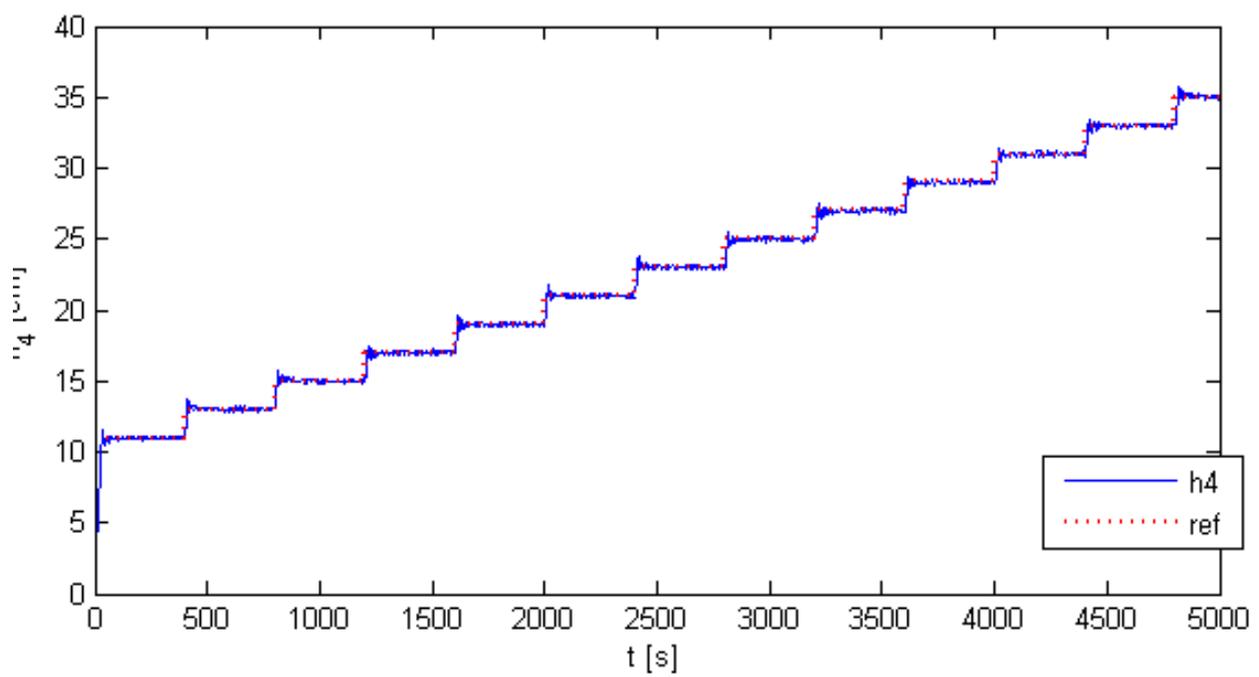
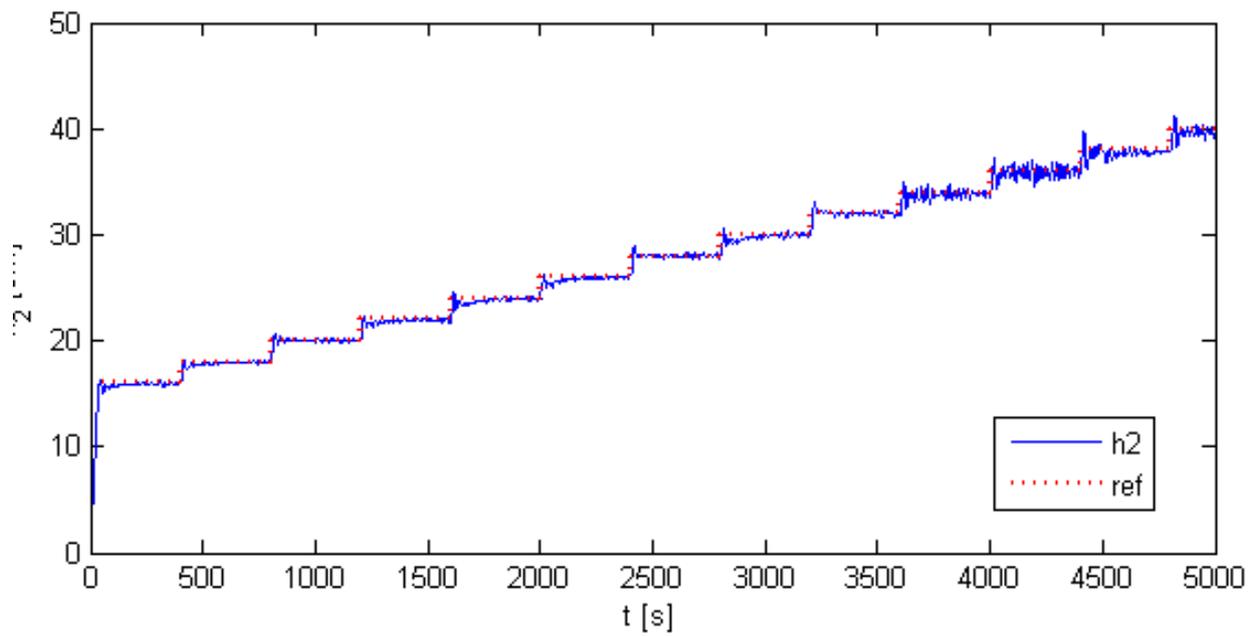


Figura 7.18: Valores medidos e referência da aplicação de controle MPC com LEA em toda a faixa de operação do sistemas de nível de líquidos

7.3.1 Controle Preditivo Baseado em Modelo com Linearização Exata

O controle MPC associado foi associado a linearização exata do sistema de nível de líquidos, sendo que os valores utilizados não eram os valores reais do sistema, ver Tabelas 7.1, 7.2 e 7.3 de mudanças nos parâmetros durante o experimento. Com isso aplicou-se o controle preditivo sem característica antecipativa. A Figura 7.19 mostra o resultado da estimação dos estados pelo FKE, já que a característica que não foi associada foi a estimação dos parâmetros.

A Figura 7.20 mostra detalhes do controle. Fica visivelmente claro que o sistema possui uma característica oscilatória perto da objetivo mais visível no nível dos tanques 1 e 2, já no tanque 4 o resultado deixou um erro em regime permanente. Este fato mostra a importância dos valores dos parâmetros do modelo no procedimento de linearização exata. O sinal de controle da linearização exata apresentado na Figura 7.21 ressalta que o sistema trabalha de forma semelhante a um controlador liga-desliga, oscilando entre os valores máximo e mínimo do atuador, na aplicação real esta característica pode nem mesmo ser percebida, pois dada a frequência do sinal de atuação pode ser o atuador filtre parte deste melhorando o resultado do controle.

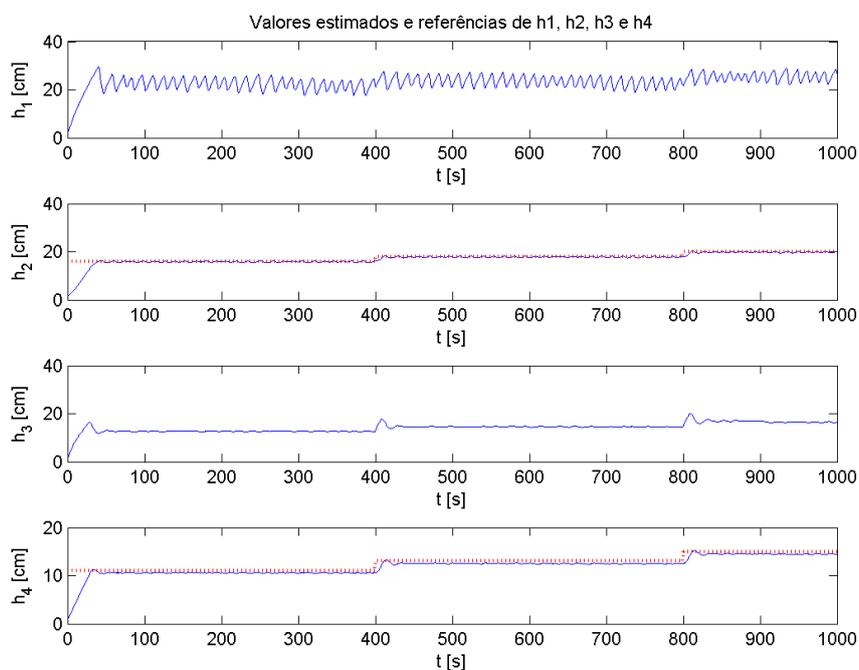


Figura 7.19: Valores estimados dos estados - LE controle MPC

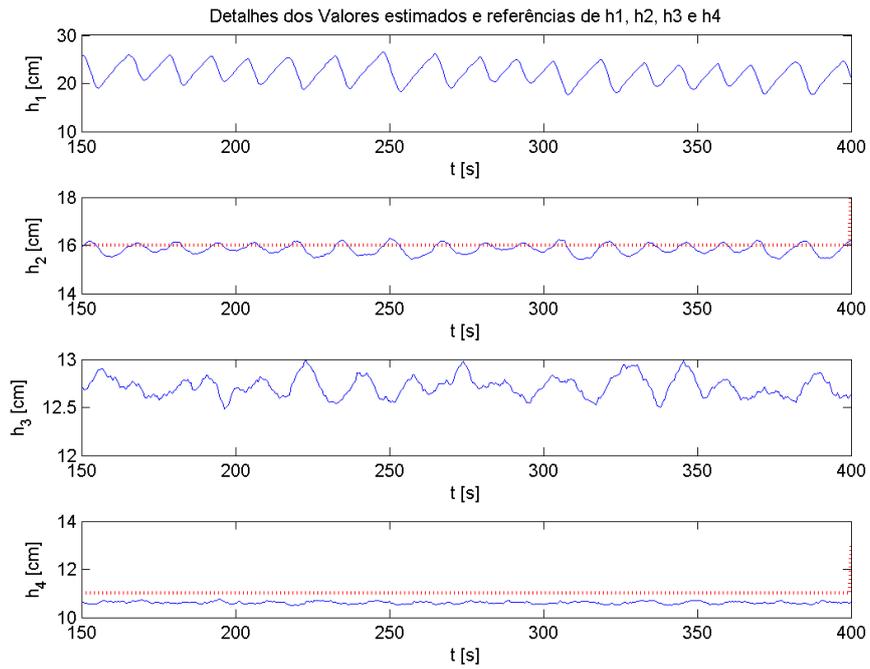


Figura 7.20: Detalhe dos valores estimados dos estados - LE controle MPC

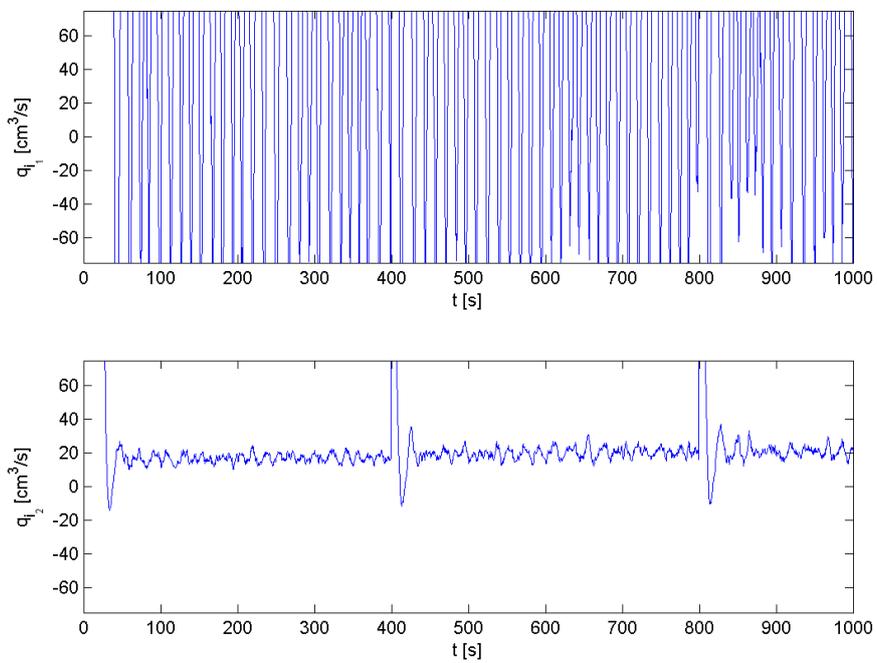


Figura 7.21: Sinal dos atuadores - LE controle MPC

7.4 Resumo

Na Secção 7.2 apresentou-se a invariância ao ponto de operação e à mudança de valores nos parâmetros do sistema proveniente da associação entre a linearização exata adaptativa e o controle PI de sistemas lineares de uma entrada e uma saída.

Na Secção 7.3 a Figura 7.18 apresentou-se a invariância do conjunto LEA-MPC em relação ao ponto de operação do sistema de nível de líquidos, bem como em relação à mudança de valores nos parâmetros durante a execução de um experimento. Ou seja, esse experimento valida a LEA associada ao MPC para controle de sistemas não-lineares. O MPC foi aplicado como controlador de sistemas multivariável, mas poderia também ser decomposto em dois controladores de sistemas SISO.

A Secção 7.3.1 apresentou-se a associação entre a linearização exata e o controle preditivo baseado em modelo que produz um controlador invariante ao ponto de operação do sistema de nível de líquidos, porém este controlador depende dos corretos valores de parâmetros utilizados na linearização exata. Assim pode-se afirmar que para sistemas como este a aplicação da linearização exata é insuficiente, pois não possui robustez em relação à variação dos valores dos parâmetros do sistema não-linear.

Capítulo 8

Conclusões e Pesquisa Futuras

8.1 Conclusões

A linearização exata adaptativa abordada neste trabalho composta pela associação da linearização exata clássica com um estimador recursivo, no caso o filtro de Kalman estendido, foi detalhadamente apresentada e mostrou-se uma solução para a aplicação de técnicas de controle linear a sistemas não-lineares, assim evita-se os problemas dos sistemas não-lineares com as vantagens do controle linear. A utilização da Linearização Exata com controle preditivo mostra-se uma abordagem mais efetiva que a abordagem de utilização de modelos locais utilizada e mais simples que a abordagem de uso das equações não-lineares na função de custo do controlador.

Os resultados apresentados nesse trabalho mostraram a eliminação da influência do ponto de operação em sistemas lineares no resultado do controle do processo, ou seja o controle gerar os mesmos resultados em toda a faixa de operação do processo. No capítulo 7 a LEA foi aplicada em conjunto com controle PI e com MPC controlando o sistema de nível de líquidos em toda sua faixa de operação, sem necessidade de alterações no controlador. Como a linearização exata adaptativa gera um modelo linear pode aplicar as técnicas de controle linear a sistema como o sistema de nível de líquidos, desde que seja possível realizar a linearização exata do processo.

Alguns fatores característicos de sistemas adaptativos que não estão no escopo do estudo deste trabalho como a estabilidade podem ter seus problemas minimizados utilizando-se uma taxa de atualização dos parâmetros superior a taxa de amostragem do sistema. Assim o FKE não realizaria a atualização dos parâmetros da linearização exata a cada instante de tempo, mas por exemplo, a cada 20 amostras. O filtro de Kalman estendido funcionou muito bem para estimação conjunta de estados e parâmetros do sistema, mas outra forma de minimizar possíveis problemas seria a redução do número de parâmetros estimados pelo FKE a aqueles que sofrem variações durante os experimentos.

O Controle Preditivo Baseado em Modelo é uma técnica que não só tem aceitação acadêmica e industriais como produz bons resultados numa grande diversidade de sistemas. Uma das dificuldades de utilização de técnicas de Controle Preditivo é a grande quantidade de parâmetros configuráveis, como pesos de entrada e saída, horizontes de controle e predição, bem como quando aplicar tais horizontes. Ou seja o tuning do controlador preditivo não é fácil nem existe uma

estratégia unificada e bem definida para tal, se o controle MPC já possui tantas variantes imagine um controle que a função a ser minimizada tem com base funções não-lineares nesse contexto de complicação e grande liberdade o uso da Linearização Exata para gerar e utilizar o modelo num controlador MPC é bastante eficaz como mostrado nesse trabalho para o caso Multivariável.

8.2 Pesquisa Futuras

Como pesquisas futuras tem-se as seguintes propostas:

- Estudo teórico da estabilidade da linearização exata adaptativa;
- Aplicação do controle preditivo com característica antecipativa ao sistema de nível;
- Comparação da linearização exata adaptativa com outras técnicas que possibilitam controlar sistemas não-lineares com técnicas de controle linear.

REFERÊNCIAS BIBLIOGRÁFICAS

- [Abdenmour M. Ksouri 2002]ABDENNOUR M. KSOURI, F. M. R. Nonlinear model-based predictive control using a generalised Hammerstein model and its application to a semi-batch reactor. *The International Journal of Advanced Manufacturing Technology*, v. 20, n. 11, p. 844–852, November 2002.
- [Aguirre 2004]AGUIRRE, L. A. *Introdução à Identificação de Sistemas - Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais, Segunda Edição Revista e Ampliada*. [S.l.]: Editora UFMG, 2004.
- [Aguirre, Rodrigues e Mendes 1997]AGUIRRE, L. A.; RODRIGUES, G. G.; MENDES, E. M. A. M. Non-linear identification and cluster analysis of chaotic attractors from a real implementation of chua’s circuit. *International Journal of Bifurcation and Chaos*, v. 7, n. 6, p. 1411–1423, 1997.
- [Aragones, Borges e Fournier 2002]ARAGONES, J.; BORGES, G. A.; FOURNIER, A. Isr’2002. In: *Accuracy Improvement for a Redundant Vehicle*. [S.l.: s.n.], 2002.
- [Bauchspiess, Alfaro e Dobrzanski 2001]BAUCHSPIESS, A.; ALFARO, S. C. A.; DOBRZANSKI, L. A. Predictive sensor guided robotic manipulators in automated welding cells. *Journal of Materials Processing Technology*, 2001.
- [Bellemans, De Schutter B. e De Moor 2006]BELLEMANS, T.; De Schutter B., W. G.; De Moor, B. Model predictive control for ramp metering combined with extended kalman filter-based traffic state estimation. In: *Intelligent Transportation Systems Conference, 2006. ITSC '06. IEEE*. [S.l.: s.n.], 2006. p. 406–411.
- [Bemporad 1997]BEMPORAD, A. *Reference Governors: On-Line Set-Point Optimization Techniques for Constraint Fulfillment*. Tese (Doutorado) — Control and Computer Engineering University di Firenze, Italy, 1997.
- [Bernardes et al. 2006]BERNARDES, M. et al. Instrumentação e identificação não-linear de um sistema de nível de líquido com quatro tanques interligados. In: *CBA, Congresso Brasileiro de Automática*. [S.l.: s.n.], 2006.
- [Bitencourt Junior 2003]Bitencourt Junior, H. *Métodos de Estimação Recursiva Baseados no Filtro de Kalman Aplicados a Sistemas Não-Lineares*. Dissertação (Mestrado) — Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais, November 2003.

- [Bitencourt Junior, Torres e Aguirre 2004]BITENCOURT JUNIOR, H.; TORRES, L. A. B.; AGUIRRE, L. A. Estimação conjunta de estados e parâmetros com o filtro de kalman unscented: Um estudo de caso usando o circuito de chua. In: *Congresso Brasileiro de Automática 2004, 2004, Gramado - RS. Anais do CBA 2004, 2004*. [S.l.: s.n.], 2004.
- [Bloemen, Boom e Verbruggen 2000]BLOEMEN, H.; BOOM, T.; VERBRUGGEN, H. Model-based predictive control for Hammerstein systems. In: *Decision and Control, 2000. Proceedings of the 39th IEEE Conference on*. [S.l.: s.n.], 2000. p. 4963–4968.
- [Bølviken et al. 2001]BØLVIKEN, E. et al. Monte Carlo filters for non-linear state estimation. *Automatica*, v. 37, p. 177–183, 2001.
- [Borges G.A. 2006]BORGES G.A., M. L. Uncertainty propagation in transmission line modeling (tln) method. *Frontiers on Applied computational Electromagnetics, FACE Digest*, v. 1, p. 13–16, 2006.
- [Camacho e Bordons 2003]CAMACHO, E. F.; BORDONS, C. *Model Predictive Control*. [S.l.]: Springer, 2003.
- [Cervantes, Agamennoni e Figueroa 2003]CERVANTES, A. L.; AGAMENNONI, O. E.; FIGUEROA, J. L. A nonlinear model predictive control system based on Wiener piecewise linear models. *Journal of Process Control*, v. 13, n. 7, p. 655–666, October 2003.
- [Chen e Liu 2000]CHEN, R.; LIU, J. S. Mixture Kalman filters. *Journal of the Royal Statistical Society: Series B (Methodological)*, v. 62, n. 3, p. 493–508, 2000. Disponível em: <http://www.people.fas.harvard.edu/~junliu/TechRept/00.html>.
- [Clark, Mohtadi e Tuffs 1987]CLARK, D. W.; MOHTADI, C.; TUFFS, P. Generalized Predictive Control \tilde{U} part i: the basic algorithm. *Automatica*, 1987.
- [Clark, Mohtadi e Tuffs 1987]CLARK, D. W.; MOHTADI, C.; TUFFS, P. Generalized Predictive Control \tilde{U} part ii: extensions and interpretations. *Automatica*, 1987.
- [Clarke, Mohtadi e Tuffs 1987]CLARKE, D. W.; MOHTADI, C.; TUFFS, P. S. Generalized predictive control. i - the basic algorithm. ii - extensions and interpretations. *Automatica.*, v. 23, p. 137–160, march 1987.
- [Devasia, Chen e Paden 1996]DEVASIA, S.; CHEN, D.; PADEN, B. Nonlinear inversion-based output tracking. *IEEE Transactions on Automatic Control*, 1996.
- [Doucet, Freitas e Gordon 2001]DOUCET, A.; FREITAS, N. de; GORDON, N. *Sequential Monte Carlo Methods in Practice*. [S.l.]: Springer-Verlag, 2001.
- [Findeisen 2002]FINDEISEN, F. A. R. An introduction to nonlinear model predictive control. In: *21st Benelux Meeting on Systems and Control, 2002, Veldhoven*. [S.l.: s.n.], 2002.
- [Foss, Johansen e Sorenson 1994]FOSS, B.; JOHANSEN, T. A.; SORENSON, A. V. Nonlinear predictive control using local models – applied to a batch process. In: *IFAC ADCHEM 94, Kyoto, Japan*. [S.l.: s.n.], 1994.

- [Franco 2006]FRANCO, A. *CONTROLE NÃO LINEAR ROBUSTO: UM MÉTODO BASEADO EM UMA LINEARIZAÇÃO POR REALIMENTAÇÃO*. Tese (Doutorado) — Departamento de Automação e Sistemas, Universidade Federal de Santa Catarina - UFSC, 2006.
- [Franco et al. 2006]FRANCO, A. et al. Robust nonlinear control associating robust feedback linearization and H_∞ control. *IEEE Transactions on Automatic Control*, v. 51, n. 7, p. 1200–1207, 2006.
- [Franklin, Powell e Workman 1997]FRANKLIN, G. F.; POWELL, J. D.; WORKMAN, M. L. *Digital Control of Dynamic Systems*. [S.l.]: Addison Wesley Longman, 1997.
- [Freitas, Borges e Bauchspiess 2004]FREITAS, A. A.; BORGES, G. A.; BAUCHSPIESS, A. Avaliação do filtro de kalman estendido para estimação de parâmetros de processo de nível de líquidos. In: *CBA, Congresso Brasileiro de Automática*. [S.l.: s.n.], 2004.
- [Freitas, Borges e Bauchspiess 2004]FREITAS, A. A.; BORGES, G. A.; BAUCHSPIESS, A. State space control and extended kalman filter estimation applied to a 3rd order liquid level process. In: *INDUSCON*. [S.l.: s.n.], 2004.
- [Fruzzeti, Palazoglu e Mcdonald 1997]FRUZZETI, K.; PALAZOGLU, A.; MCDONALD, K. Non-linear model predictive control using Hammerstein models. *Journal of Process Control*, v. 7, n. 1, p. 31–41, 1997.
- [Gomez, Jutan e Baeyens 2004]GOMEZ, J.; JUTAN, A.; BAEYENS, E. Wiener model identification and predictive control of a pH neutralisation process. *IEE Proceedings - Control Theory and Applications*, v. 151, n. 3, p. 329– 338, 2004.
- [Gosmann 2002]GOSMANN, H. L. *Um Sistema Multivariável de Tanques Acoplados para Avaliação de Técnicas de Controle*. Dissertação (Mestrado) — Departamento de Engenharia Elétrica, Universidade de Brasília, 2002.
- [Hangos, Bokor e Szederkényi 2004]HANGOS, K.; BOKOR, J.; SZEDERKÉNYI, G. *Analysis and control of nonlinear process systems*. [S.l.]: Springer-Verlag, 2004.
- [Haykin 2001]HAYKIN, S. *KALMAN FILTERING AND NEURAL NETWORKS*. [S.l.]: John Wiley & Sons, 2001.
- [Haykin 2001]HAYKIN, S. *Redes Neurais : Princípios e Prática*. [S.l.]: Bookman, 2001.
- [Huang e Lewis 2003]HUANG, J.-Q.; LEWIS, F. Neural-network predictive control for nonlinear dynamic systems with time-delay. *Neural Networks, IEEE Transactions on*, v. 14, n. 2, p. 377 – 389, 2003.
- [Imsland, Bar e Foss 2005]IMSLAND, L.; BAR, N.; FOSS, B. A. More efficient predictive control. *Automatica*, 2005.
- [Isermann R. 1992]ISERMANN R., L. K.-H. M. D. *Adaptive control Systems*. [S.l.]: Prentice-Hall, 1992.
- [Isidori 1989]ISIDORI, A. *Nonlinear Control Systems*. [S.l.]: Springer-Verlag, 1989.

- [Jazwinski 1970]JAZWINSKI, A. H. *Stochastic Processes and Filtering Theory*. [S.l.]: Academic Press, 1970.
- [Julier, Uhlmann e Durrant-Whyte 2000]JULIER, S. J.; UHLMANN, J.; DURRANT-WHYTE, H. F. A new method for the nonlinear transformation of means and covariances in filters and estimators. *IEEE Transactions on Robotics and Automation*, v. 45, n. 3, p. 477–482, 2000.
- [Kalman 1960]KALMAN, R. E. A new approach to linear filtering and prediction problems. *Transactions of the ASME - Journal of Basic Engineering*, v. 82, p. 35–45, 1960.
- [Kalman e Bucy 1961]KALMAN, R. E.; BUCY, R. S. New results in linear filtering and prediction theory. *Transactions of the ASME - Journal of Basic Engineering*, v. 83, p. 95–107, 1961.
- [Kishor e Singh 2007]KISHOR, N.; SINGH, S. Nonlinear predictive control for a nnarx hydro plant model. *Neural Computing & Applications*, 2007.
- [Ko, Strganac e Kurdila 1999]KO, J.; STRGANAC, T.; KURDILA, A. Adaptive feedback linearization for the control of a typical wing section with structural nonlinearity. *Nonlinear Dynamics*, v. 18, n. 3, p. 289–301, 1999.
- [Leu e Baratti 2000]LEU, G.; BARATTI, R. An extended kalman filtering approach with a criterion to set its tuning parameters; application to a catalytic reactor. *Computer & Chemical Engineer*, v. 23, p. 1839–1849, 2000.
- [Liu e Chen 1998]LIU, J.; CHEN, R. Sequential Monte Carlo methods for dynamic systems. *Journal of the American Statistical Association*, v. 93, p. 1032–1044, 1998.
- [Ljung 1999]LJUNG, L. *System Identification - Theory for the User*. [S.l.]: Prentice-Hall, 1999.
- [Ljung e Glad 1994]LJUNG, L.; GLAD, T. *Modeling of Dynamic Systems. Information and System Sciences Series*. [S.l.]: Prentice-Hall, 1994.
- [Lu e Tsai 2007]LU, C.-H.; TSAI, C.-C. Generalized predictive control using recurrent fuzzy neural networks for industrial processes. *Journal of Process Control*, v. 17, n. 1, p. 83–92, January 2007. Disponível em: <<http://www.sciencedirect.com/science/article/B6V4N-4M2WP0V-2/2/d225504227b328ddd28326e1499d7fc1>>.
- [Peng, Nakano e Shioya 2007]PENG, H.; NAKANO, K.; SHIOYA, H. Nonlinear predictive control using neural nets-based local linearization ARX model stability and industrial application. *Control Systems Technology, IEEE Transactions on*, v. 15, n. 1, p. 130–143, 2007.
- [Pimenta 2003]PIMENTA, K. B. *Controle de juntas robóticas usando Controlador Preditivo Generalizado Adaptativo Direto*. Tese (Doutorado) — Universidade Estadual de Campinas, 2003.
- [Poulsen, Kouvaritakis e Cannon 2001]POULSEN, N. K.; KOUVARITAKIS, B.; CANNON, M. Nonlinear constrained predictive control applied to a coupled-tank apparatus. *IEE Proceedings - Control Theory Applications*, v. 148, n. 1, January 2001.
- [Qin e Badgwell]QIN, S.; BADGWELL, T. An overview of nonlinear model predictive control applications. Disponível em: <citeseer.ist.psu.edu/qin00overview.html>.

- [Qin e Badgwell 1996]QIN, S.; BADGWELL, T. A. An overview of industrial model predictive control technology. In: *Proceedings CPC-V, Lake Tahoe*. [S.l.: s.n.], 1996.
- [Richalet 1993]RICHALET, J. Industrial applications of model based predictive control. *Automatica*, v. 29, n. 5, p. 1251–1274, 1993.
- [Rossiter 2003]ROSSITER, J. A. *Model-Based Predictive Control - A Practical Approach*. [S.l.]: CRC Press, 2003.
- [Schön 2001]SCHÖN, T. *Identification for Predictive Control - A Multiple Model Approach*. Dissertação (Mestrado) — Department of Electrical Engineering, Linköping University, Sweden, 2001.
- [Simon 2006]SIMON, D. *Optimal State Estimation: Kalman, H-infinity, and Nonlinear Approaches*. [S.l.]: John Wiley & Sons, 2006.
- [Smith e Hashtrudi-Zaad 2005]SMITH, A.; HASHTRUDI-ZAAD, K. van. Neural network-based teleoperation using smith predictors. In: *Mechatronics and Automation, 2005 IEEE International Conference*. [S.l.: s.n.], 2005. p. 1654–1659.
- [Sousa 1998]SOUSA, E. de. *Sobre o Método de Interpolação Polinomial para o Problema de Linearização Exata*. Tese (Doutorado) — Universidade Federal de Uberlândia, 1998.
- [Wan, Merwe e Nelson 2000]WAN, E. A.; MERWE, R. van der; NELSON, A. T. Dual estimation and the unscented transformation. *MIT Press Advances in Neural Information Processing Systems*, v. 12, p. 666–672, November 2000.
- [Williams 1992]WILLIAMS, R. J. Training recurrent networks using the extended kalman filter. In: *International Joint Conference on Neural Networks*. [S.l.: s.n.], 1992. p. 241–246.
- [Yun et al. 2005]YUN, L.-J. et al. Stability of state feedback two-step mpc for input saturated uncertain Hammerstein model. In: *Machine Learning and Cybernetics, 2005. Proceedings of 2005 International Conference on*. [S.l.: s.n.], 2005. p. 574–579.
- [Zhang e Singh 2001]ZHANG, R.; SINGH, S. N. Adaptive output feedback control of an aeroelastic system with unstructured uncertainties. *Journal of Guidance, Control, and Dynamics*, v. 24, n. 3, p. 502–509, 2001.